



**Pedro A. Afonso
Esteves**

**Aprendizagem Automática Aplicada a Interfaces
Cérebro-Computador**



**Pedro A. Afonso
Esteves**

Aprendizagem Automática Aplicada a Interfaces Cérebro-Computador

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia Electrónica e Telecomunicações, realizada sob a orientação científica do Doutor Filipe Silva, Professor Auxiliar da Universidade de Aveiro, e co-orientação do Doutor Paulo Dias, Professor Auxiliar na mesma Universidade.

o júri / the jury

Presidente / President

Doutora Ana Maria Perfeito Tomé

Professora Associada da Universidade de Aveiro

Vogais / Examiners committee

Doutor Nuno Sérgio Mendes Dias

Investigador do Departamento de Electrónica Industrial
Escola de Engenharia da Universidade do Minho

Doutor Filipe Miguel Teixeira Pereira da Silva

Professor Auxiliar da Universidade de Aveiro

Doutor Paulo Miguel de Jesus Dias

Professor Auxiliar da Universidade de Aveiro

**agradecimentos /
acknowledgements**

Aos meus orientadores, Filipe Silva e Paulo Dias, pelo valioso sentido crítico que, desde o princípio, souberam transmitir. Em especial, ao Prof. Filipe Silva devo uma persistência e pragmatismo que nem sempre tive.

Ao Frederico Valente, pela inestimável ajuda no desenvolvimento dos ambientes gráficos.

A Luís Paula, pelo seu valor humano e disponibilidade permanente em ajudar e a Virgílio Bento, pela qualidade das suas ideias. A ambos, agradeço o legado intelectual que, com a presente dissertação, pretendo honrar.

Aos meus pais, ao meu irmão André e à Sara.

Palavras-Chave

Interface Cérebro-Computador (BCI), Electroencefalograma (EEG), Imaginação Motora, Extracção de Características, Classificação, Realidade Virtual.

Resumo

O grupo *IEETA-BCI* desenvolve, há vários anos, experiências com *interfaces* do tipo BCI, e os resultados são promissores. Algumas técnicas para aquisição de sinal, extracção de características e classificação foram já desenvolvidas. Como diversos estudos comprovam, as propriedades que melhor permitem identificar certos padrões em sinais EEG têm sido reportadas a determinadas regiões corticais e a certas bandas de frequência. Tirando partido desse conhecimento *a priori*, é possível tratar os dados, reduzindo a entropia na entrada. No entanto, tais soluções são, por norma, independentes do utilizador: os eléctrodos seguem uma localização padrão e os filtros dimensionados têm margens bem definidas. Nesse sentido, o grande objectivo da presente investigação é o de procurar uma forma mais abrangente de seleccionar, em cada indivíduo, um sub-conjunto personalizado de propriedades (presentes nos dados) que maximizem a discriminação de estados mentais, em particular aqueles que dizem respeito a padrões ERD/ERS, nomeadamente nos ritmos *mu*.

Enquanto trabalho direccionado à classificação, faz-se um estudo da natureza e qualidade dos dados a discriminar, e apresenta-se o método que determina a relevância de certas características, no problema de classificação. Ainda que sem perda de generalidade, tais módulos de extracção de características e classificação serão pensados numa filosofia de aplicação em operações assíncronas, como a navegação em ambientes gráficos/virtuais. Por ser a que permite um maior grau de iniciativa ao utilizador, é na operação assíncrona que se concentra, hoje, o desenvolvimento de BCIs e daí poderão advir, potencialmente, as aplicações mais interessantes.

Keywords

Brain-Computer Interface (BCI), Electroencephalogram (EEG), Motor Imagery, Feature Extraction, Classification, Virtual Reality.

Abstract

In the course of the last years, IEETA-BCI has come to experiment with brain-computer interfaces, showing promising results. Techniques have been developed for signal acquisition, feature extraction and pattern classification. Certain patterns of interest in EEG signals can be roughly mapped to particular cortical areas and specific frequency bands. Such knowledge can be used to reduce the entropy of the incoming data. Generally, these methods do not take into account the specificities of the subject, electrodes being placed on standard locations, the filters created with well defined bands. In this thesis it is proposed a new set of methodologies in order to automatically discover and discriminate a group of relevant features from the original signal, thereby improving the performance on the correct classification of mental states, in a per-individual basis.

Concerning pattern classification, a comparative study has been made between several methods. We focus on both the source of the input data and its respective quality and relevance as well as on the classification method itself. The implemented modules, for feature extraction and classification, were planned and developed following an asynchronous operation paradigm with view of their posterior usage on virtual environments. By providing greater user initiative, it is in asynchronous operations that BCI research is currently focused, being expected to spawn the most interesting applications.

*Trago um Fado escondido
Na palavra navegar
Onde o Fado é mais sentido
E antes de ser Fado é mar.*

*Eu trago um Fado guardado
Dentro da palavra amor
Que é onde o Fado é mais Fado
E antes de ser Fado é dor.*

*Trago um Fado que nasceu
Na palma da minha mão
Onde o Fado é teu e meu
E antes de Fado é paixão.*

Trago um Fado (Cristina Branco)

Aos meus Pais.

Conteúdo

Conteúdo	i
Lista de Figuras	v
Lista de Tabelas	ix
Lista de Acrónimos	xi
1 Introdução	1
2 Estado da Arte	3
2.1 Legado Histórico	4
2.2 O Cérebro Humano	5
2.2.1 A Neurofisiologia do Movimento	7
2.2.2 A Imaginação Motora	7
2.3 Leitura de Sinais Cerebrais	9
2.3.1 Electroencefalograma (EEG)	9
2.3.2 Outros Aparelhos: <i>Que viabilidade numa BCI?</i>	10
2.4 Aquisição de Sinais EEG	10
2.4.1 Actividade Rítmica Cerebral	10
2.4.2 Atenuação e Dispersão	13
2.4.3 Artefactos	14
2.4.3.1 Artefactos Biológicos	14
2.4.3.2 Artefactos Ambientais	15
2.4.3.3 Correção de Artefactos	15
2.4.4 Disposição dos Eléctrodos	15
2.4.4.1 <i>Common Average Reference</i> (CAR)	16
2.4.4.2 Montagem Laplaciana	16
2.5 BCIs baseadas em sinais EEG	17
2.5.1 Paradigmas de Operação	18
2.5.2 Casos de Sucesso	19

2.5.2.1	Wadsworth Center	20
2.5.2.2	Graz University	20
2.5.2.3	Millán BCI: <i>Brain-Actued Interaction</i>	20
3	O Problema do Controlo de uma BCI	21
3.1	Ferramentas de Treino - Controlo Voluntário da Actividade Cerebral	22
3.1.1	Ambiente de Aquisição/Calibração	23
3.1.2	Ambiente Gráfico Virtual	23
3.1.2.1	Motor Gráfico <i>OGRE3D</i>	25
3.1.2.2	Modelação de Objectos <i>3D</i>	27
3.2	Aprendizagem Automática - Adaptação da Máquina ao Utilizador	27
3.2.1	Métodos de Aprendizagem	29
3.2.1.1	Análise Linear Discriminante	29
3.2.1.2	Redes Neurais	30
3.2.1.3	<i>SVMs</i>	31
3.2.1.4	Extracção de Características com Algoritmos Genéticos	32
3.2.1.5	Considerações Finais	32
3.2.2	Metodologia Adoptada	34
3.2.2.1	Extracção de Características Relevantes para Classificação	34
3.2.2.2	Classificador Baseado na Análise Discriminante de Fisher	36
3.2.3	Dados de Treino e Teste	37
3.2.4	Ambiente de Desenvolvimento	38
3.2.4.1	<i>Matlab</i>	38
3.2.4.2	<i>Simulink</i>	39
3.2.4.3	<i>EEGLab</i>	39
4	Adaptação Baseada em Aprendizagem	41
4.1	Filtragem Passa-Banda e Espectro de Potência	41
4.2	Análise dos dados de Martigny	44
4.2.1	Derivações Bipolares e Janelas Temporais	45
4.2.2	Frequências Relevantes para Discriminação	47
4.2.3	Evolução da Classificação	53
4.3	Análise dos dados de Berlim	57
4.3.1	Estudo com Derivações Bipolares	57
4.3.1.1	Sujeito “aa”	58
4.3.1.2	Sujeito “al”	60
4.3.1.3	Sujeito “av”	62
4.3.1.4	Sujeito “ay”	64

4.3.1.5	Sujeito “aw”	66
4.3.2	Estudo com Componentes Independentes (ICA)	68
4.3.2.1	Sujeito “aa”	68
4.3.2.2	Sujeito “al”	70
4.3.2.3	Sujeito “av”	72
4.3.2.4	Sujeito “ay”	74
4.3.2.5	Sujeito “aw”	76
4.4	Discussão dos resultados	76
5	Conclusões	81
	Bibliografia	85

Lista de Figuras

2.1	Gustav Theodor Fechner (1801–1887) (Fonte: http://commons.wikimedia.org)	4
2.2	Mapeamento Funcional do Córtex Cerebral Humano (Fonte: www.scienceblogs.com)	6
2.3	Representação de Neurónios (Fonte: http://www.sobiologia.com.br)	6
2.4	Áreas corticais responsáveis pela execução motora (Fonte: http://brainconnection.positscience.com)	7
2.5	Homunculus Motor (Fonte: http://www.harmonicresolution.com/)	8
2.6	Ritmos <i>Delta</i>	11
2.7	Ritmos <i>Theta</i>	11
2.8	Ritmos <i>Alpha</i>	12
2.9	Ritmos <i>mu</i>	12
2.10	Ritmos <i>Beta</i>	13
2.11	Ritmos <i>Gamma</i>	13
2.12	Representação das três meninges que envolvem o cérebro humano (Fonte: Mayo Foundation for Medical Education and Research)	13
2.13	Sistemas para posicionamento dos eléctrodos no escalpe humano	16
2.14	Multidisciplinaridade de um sistema BCI	17
3.1	<i>Qt Creator</i> : Ferramenta utilizada no desenvolvimento do ambiente gráfico de treino e calibração	24
3.2	Quatro cenários distintos, para vários estados, na plataforma gráfica de treino (ou calibração) desenvolvida	24
3.3	Ambiente virtual desenvolvido, com formato de uma arena	25
3.4	Interface em Matlab, para registo dos detalhes de cada utilização no ambiente gráfico-virtual	26
3.5	<i>Blender</i> : Ferramenta para modelação de objectos 3-D	27
3.6	Interface da ferramenta de modelação gráfica 3-D <i>QuArK</i> ®, no desenvolvimento de um cenário em forma de arena	28
3.7	Interface <i>freeware</i> mais usada para modelação 3-D: <i>GTKRadiant</i> ©	28
3.8	Representação simplificada de uma rede neuronal artificial “ <i>feedforward</i> ” (Fonte : <i>Wikipedia</i>)	30
3.9	Arquitectura do sistema para sub-divisão do espaço de características dos sinais EEG. A divisão é feita num estilo “ <i>wrapper</i> ”, pelo que é direccionada à <i>performance</i> do classificador (que poderá ser, por exemplo, uma SVM)	32

3.10	<i>Principal Component Analysis</i> e <i>Linear Discriminant Analysis</i> : duas estratégias, com propósitos distintos, para redução da dimensionalidade dos dados	33
3.11	Aspecto visual da toolbox <i>EEGLAB</i>	40
4.1	Resposta em frequência do filtro passa-banda utilizado	42
4.2	Densidade Espectral de Potência (para 7 canais monopolares) de sinais EEG, sem filtragem, obtidos durante uma sessão. Pode observar-se que a distribuição espacial de energia na banda <i>alpha</i> varia bastante (de facto, é mais proeminente na região parietal). A influência da frequência da rede eléctrica (50Hz) é também evidente	43
4.3	Plataforma Simulink para estudos comparativos de diversos métodos de estimativa de DEPs	44
4.4	A plataforma permite um acompanhamento dinâmico da evolução do espectro com o tempo amostral; apresenta-se um exemplo da distribuição do espectro de energia, estimado pelos três métodos contemplados, ambos de ordem 20, e com uma janela FFT de 128 valores para um <i>buffer</i> com 256 amostras, correspondentes – no <i>dataset</i> de Martigny – a um segundo de aquisição	44
4.5	Derivações bipolares mais relevantes para o Sujeito 1 de Martigny, na discriminação de cada par de classes.	46
4.6	Derivações bipolares mais relevantes para o Sujeito 2 de Martigny, na discriminação de cada par de classes.	46
4.7	Derivações bipolares mais relevantes para o Sujeito 3 de Martigny, na discriminação de cada par de classes.	47
4.8	Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes	48
4.9	Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes	49
4.10	Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes	49
4.11	Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes	50
4.12	Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes	50
4.13	Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes	51
4.14	Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes	51
4.15	Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes	52
4.16	Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes	52
4.17	Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 1 de Martigny	54
4.18	Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 2 de Martigny	55

4.19	Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 3 de Martigny	55
4.20	Classificação alternativa, ilustrada para o Sujeito 3 de Martigny, usando agora a totalidade das “ <i>features</i> ” disponíveis, num total de 28 derivações bipolares vezes 14 frequências (i.e., 392 “ <i>features</i> ” de entrada)	56
4.21	Distribuição de eléctrodos EEG utilizada. O sentido das setas entre eléctrodos mostra as derivações bipolares analisadas ($\oplus \rightarrow \ominus$)	57
4.22	Derivações bipolares <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ aa ” de Berlim	58
4.23	Frequências mais relevantes, para o sujeito “ aa ” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	58
4.24	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ aa ” de Berlim . .	59
4.25	Derivações bipolares <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ al ” de Berlim	60
4.26	Frequências mais relevantes, para o sujeito “ al ” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	60
4.27	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ al ” de Berlim . .	61
4.28	Derivações bipolares <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ av ” de Berlim	62
4.29	Frequências mais relevantes, para o sujeito “ av ” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	62
4.30	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ av ” de Berlim . .	63
4.31	Derivações bipolares <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ aw ” de Berlim	64
4.32	Frequências mais relevantes, para o sujeito “ aw ” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	64
4.33	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ aw ” de Berlim . .	65
4.34	Derivações bipolares <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ ay ” de Berlim	66
4.35	Frequências mais relevantes, para o sujeito “ ay ” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	66
4.36	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ ay ” de Berlim . .	67
4.37	Componentes Independentes <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ aa ” de Berlim	68
4.38	Frequências mais relevantes, para o sujeito “ aa ” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	69
4.39	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ aa ” de Berlim . .	69

4.40	Componentes Independentes <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ al ” de Berlim	70
4.41	Frequências mais relevantes, para o sujeito “ al ” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	70
4.42	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ al ” de Berlim . .	71
4.43	Componentes Independentes <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ av ” de Berlim	72
4.44	Frequências mais relevantes, para o sujeito “ av ” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	72
4.45	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ av ” de Berlim . .	73
4.46	Componentes Independentes <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ aw ” de Berlim	74
4.47	Frequências mais relevantes, para o sujeito “ aw ” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	74
4.48	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ aw ” de Berlim .	75
4.49	Componentes Independentes <i>versus</i> janelas de tempo mais discriminantes, para o sujeito “ ay ” de Berlim	76
4.50	Frequências mais relevantes, para o sujeito “ ay ” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso	76
4.51	Evolução da Classificação para os <i>sets</i> de treino e teste, no Sujeito “ ay ” de Berlim . .	77
4.52	Melhores resultados obtidos na BCI Competition III, para o dataset de Martigny, de acordo com as regras. O campo “psd” indica se os sujeitos utilizaram um conjunto pré-calculado de DEPs, também disponibilizadas na competição; no caso do presente estudo, como se sabe, fez-se toda a cadeia de pré-processamento, pelo que os dados “psd” foram ignorados	78
4.53	Melhores resultados obtidos na BCI Competition III, no dataset de Martigny, para aqueles participantes que usaram janelas de normalização superiores a 1 segundo, ou outras técnicas de pós-processamento sobre os <i>labels</i>	78
4.54	Melhores resultados obtidos na BCI Competition III, no dataset de Berlim	79

Lista de Tabelas

2.1	Ritmos cerebrais segundo a distribuição em frequências	14
4.1	Combinações Derivações-Frequências escolhidas com base nos dados de treino de cada sujeito de Martigny	53
4.2	Classificações obtidas no <i>set</i> de competição para cada sujeito de Martigny, no primeiro caso recorrendo a 1 segundo de amostras (passadas), e no segundo caso obtidas à custa de janelas de normalização maiores e, portanto, mais favoráveis à classificação . . .	78
4.3	Combinações “Derivações – Frequências” escolhidas com base na primeira metade dos dados de cada sujeito de Berlim, e respectivas classificações, aplicadas à segunda metade dos dados, relegados para teste	79
4.4	Combinações “Componentes Independentes – Frequências” escolhidas com base na primeira metade dos dados de cada sujeito de Berlim, e respectivas classificações, aplicadas à segunda metade dos dados, relegados para teste	79

Lista de Acrónimos

AI	Artificial Intelligence
ALN	Adaptive Logic Network
ANN	Artificial Neural Networks
BCI	Brain-Computer Interface
BOLD	Blood Oxygen Level Dependent
BSP	Binary Space Partitioning
BSS	Blind Source Separation
CAR	Common Average Reference
DDAG	Decision Directed Acyclic Graphs
DEP	Densidade Espectral de Potência
ECoG	Eletrocorticograma
EDF	European Data Format
EEG	Eletroencefalograma
EKG ou ECG	Electrocardiograma
EMG	Electromiograma
EOG	Electrooculograma
ERD	Event Related Desynchronization
ERP	Event Related Potential
ERS	Event Related Synchronization
FIRDA	Frontal Intermittent Rhythmic Delta
fMRI	functional Magnetic Resonance Imaging
GA	Genetic Algorithms
GUI	Graphic User Interface
HMD	Head Mounted Display

ICA	Independent Component Analysis
IHC	Interacção Humano-Computador
LDA	Linear Discriminant Analysis
M1	Primary Motor Cortex
OIRDA	Occipital Intermittent Rhythmic Delta
PET	Positron Emission Tomography
PMA	Primary Motor Area
PMd	dorsal PreMotor Cortex
PMv	ventral PreMotor Cortex
PPC	Post Parietal Cortex
RBF	Radial Basis Function
SMA	Supplementary Motor Area
SMC	Sensory Motor Cortex
SPECT	Single Photon Emission Computed Tomography
STFT	Short-Time Fourier Transform
SVM	Support Vector Machine

Capítulo 1

Introdução

“Even on the sole basis of the present states of the art of computer science and neurophysiology, one may suggest that such a feat is potentially around the corner”

– Jacques Vidal (1970)

Podem os sinais eléctricos cerebrais, observáveis, e portadores de um determinado nível de informação, ser usados no contexto de uma comunicação entre Homem e computador ou, ainda, com o propósito de controlar aparelhos externos? A esta questão, Jacques Vidal procurou responder, em 1970. O aumento da capacidade de processamento dos computadores aliado ao cada vez maior conhecimento sobre o cérebro humano dão suporte à ideia de ser possível interagir com computadores ou máquinas através do simples "pensamento". Neste domínio, as interfaces cérebro-computador (BCI do inglês *Brain-Computer Interface*) têm despertado um grande interesse na comunidade científica por representarem uma nova geração de tecnologias que permitem aos utilizadores controlar dispositivos directamente através do sistema nervoso. O objectivo central destas interfaces é transformar decisões e reacções mentais em sinais de controlo pela análise da actividade bioeléctrica do cérebro. As possibilidades de aplicação são inúmeras e tão diversas como o tratamento de diversas patologias, o controlo de dispositivos (e.g., cadeira de rodas, membros artificiais) ou os jogos de computador[1][2][3][4][5].

Existe uma grande variedade de tecnologias capazes de monitorar a actividade cerebral e que podem ser usadas na implementação de uma BCI. Contudo, os métodos não-invasivos têm merecido particular atenção por permitirem desenvolver sistemas com potencial de aplicação prática. As técnicas denominadas externas (ou não intrusivas) como o electroencefalograma (EEG), têm-se tornado úteis por mostrarem a variação dos padrões cerebrais durante exercícios mentais e por permitirem determinar as regiões do cérebro que apresentam uma alteração na actividade quando ocorrem determinadas acções ou quando se verificam estímulos externos[6][7]. A utilização de algoritmos avançados de processamento de sinal e de aprendizagem automática têm permitido avanços significativos traduzidos nas melhorias na funcionalidade dos sistemas actuais[8][9][10][11][12][13][14][15][16][17][18][19].

O plano de trabalhos desta dissertação foi enquadrado no âmbito de projectos de investigação a decorrer no Instituto de Engenharia Electrónica e Telemática de Aveiro (IEETA). Estes trabalhos culminaram no desenvolvimento da IEETA-BCI cujo paradigma de operação é baseado na detecção e classificação de alterações no sinal de EEG relacionadas com tarefas de imaginação motora e tendo em vista aplicações de controlo[20][21][22]. Estas experiências recentes foram o ponto de partida para este trabalho de dissertação visando o desenvolvimento de um conjunto de ferramentas computacionais

capazes de melhorar o desempenho global do sistema. Neste sentido, foram traçados dois objectivos principais para o trabalho: (1) o desenvolvimento de um ambiente de realidade virtual que possa ser usado na fase de treino do utilizador do sistema; e (2) o estudo, implementação e avaliação de métodos de aprendizagem automática que se adaptem a cada utilizador específico. Por um lado, pretendia-se neste trabalho dar os primeiros passos na exploração de ferramentas de realidade virtual e a sua integração no sistema BCI. A motivação para este trabalho advém das possibilidades que resultam da utilização da realidade virtual como mecanismo de realimentação na fase de treino da actividade cerebral[1][23][24]. Por outro lado, pretendia-se avaliar em que medida técnicas de aprendizagem automática são essenciais para obter um melhor desempenho global do sistema usando alguma métrica (*e.g.*, tempo de resposta, robustez a falsos positivos). A dissertação encontra-se organizada da seguinte forma: o Capítulo 2 descreve o estado da arte centrado nas BCIs baseadas em sinais de EEG. O Capítulo 3 aborda o problema do controlo de uma BCI assente nas duas aproximações encontradas na maioria das BCIs actuais: treino do utilizador *versus* adaptação dos algoritmos. No Capítulo 4 são analisados e discutidos os resultados da aplicação dos algoritmos de aprendizagem automática adoptados no trabalho. Finalmente, no Capítulo 5 são apresentadas as conclusões do trabalho desenvolvido e as perspectivas de trabalho futuro.

Capítulo 2

Estado da Arte

*“ If the human mind was simple enough to understand,
we’d be too simple to understand it. ”*

– Emerson Pugh

O ponto de vista de Pugh poderá ser, de forma implícita, o argumento que explica como o desenvolvimento de Interfaces Cérebro-Computador (BCIs) é, face a limitações de ordem tecnológicas ou mesmo ética, a área mais emergente e desconhecida no domínio das Interfaces Humano-Computador (IHCs). Os progressos que têm sido feitos honram diversas linhas de investigação (*e.g.*, Neurociência, Ciências da Computação, Inteligência Artificial, Reconhecimento de Padrões, Robótica) que, quando conjugadas, permitem minimizar a complexidade da interface a desenvolver, possibilitando uma solução tecnológica com resultados promissores.

A ideia de estabelecer uma BCI seria pela primeira vez mencionada com Vidal (1973)[25], que percebeu o potencial em dela tirar partido, identificando também algumas características dos sinais biológicos.

Na sua base está, por um lado, o trabalho do físico Richard Caton (1875), ao constatar (um século antes) que a actividade eléctrica do cérebro varia com o estímulo dos sentidos[26]¹, criando um fundamento para a invenção do electroencefalograma.

Por outro lado, referem-se os estudos de John Eccles[27], que revolucionou na compreensão da transmissão sináptica no sistema nervoso central, ou mais tarde de James Jack[28], descrevendo o fluxo de corrente eléctrica em células nervosas. Investigações desta natureza permitiram identificar, nomeadamente, o potencial de repouso de um neurónio, bem como os ‘saltos’ de potencial (mensuráveis) nele detectados: um fenómeno designado *firing*, e que será ainda introduzido neste capítulo.

Desde então, como qualquer área científica que caminha para a maturidade, estas ideias abriram a discussão sobre as possibilidades que delas resultam, como de modo recíproco, e longe da visão futurista (e quiçá optimista) de alguns autores e realizadores de ficção científica, permitiu saber quais as limitações mais significativas dessas mesmas possibilidades, quando está em jogo o estado da arte, as capacidades tecnológicas, o propósito da investigação em curso e, no limite, a imaginação.

¹Os primeiros estudos de R. Caton consistiram na colocação de eléctrodos directamente no cérebro exposto de animais.

2.1 Legado Histórico

A psicofísica lida com a natureza da relação quantitativa entre qualidades físicas e mentais. Hoje, a sua prática é ubíqua em todos os campos da neurociência que envolvem o estudo do comportamento de organismos, sejam homens ou animais.

Curiosamente, a origem da psicofísica, na sua vertente sistematizada, pode ser ligada a um indivíduo apenas: Gustav Fechner (1801-1887) (Fig. 2.1). A sua biografia exhibe algumas idiossincrasias. Nascido como filho de um pastor, estudou medicina na Universidade de Leipzig, mas nunca a praticou após ter recebido o seu diploma.




Figura 2.1: Gustav Theodor Fechner (1801–1887) (Fonte: <http://commons.wikimedia.org>)

Em virtude das competências que adquiriu traduzindo manuais de física e química, de francês para alemão, foi apontado para o cargo de professor de física na mesma universidade. No decorrer de estudos que fez sobre imagens residuais², olhando fixamente o sol (e na condição de único sujeito de teste) quase perdeu a visão. Uma grave crise pessoal, muito motivada pelos seus interesses psicológicos e filosóficos, leva-o à depressão profunda nos anos 1840s. Esse período, cerca de uma década, Fechner passou-o numa habitação escura.

Emergido do seu isolamento, adquire um novo fascínio pelo mundo, e decide partilhar algumas das suas “inquietudes” com o resto da Humanidade. Na sua concepção, expressa o resultado das suas investigações em termos matemáticos e funcionais e, ao fazê-lo, permite a interpretação teórica dos seus achados.

O seu trabalho mais notável será porventura *Elemente der Psychophysik*[29] (1860). Nele, o autor estabelece a ideia monista³ de que o mundo material e o domínio da consciência, embora não redutíveis entre si, são diferentes lados de uma mesma realidade. A sua originalidade reside na tentativa de descobrir uma relação matemática exacta entre eles. O resultado dessa análise está condensado na chamada *Lei de Weber-Fechner*, que pode ser expressa da seguinte forma:

*“Para que a intensidade de uma sensação possa crescer em progressão aritmética,
o estímulo deve aumentar em progressão geométrica.”*

A fórmula geral de Fechner para determinar a sensação recebida é portanto

²Do inglês *afterimages*, diz respeito a uma ilusão óptica que se refere às imagens que permanecem no campo visual, após a exposição à imagem original ter cessado.

³Em filosofia, monismo é o nome genérico dado às doutrinas filosóficas que admitem um só princípio constitutivo (a matéria, o espírito, a ideia), onde outras doutrinas admitem dois (dualismo) ou vários (pluralismo).

$$S = c \cdot \log(R) \quad (2.1)$$

onde S diz respeito ao número de “unidades de uma sensação”, R é o estímulo numericamente estimado e c uma constante determinada, experimentalmente, para cada ordem de sensibilidade em particular.

Ironicamente, esta posição não ajudou Fechner a convencer os seus adversários filosóficos pela denominada “teoria da identidade”⁴. “Cada sensação”, disse William James, “apresenta-se como uma unidade indivisível; e é totalmente impossível ler algum significado claro na noção de que elas são volumes de unidades combinados”.

Entretanto, os primeiros psicólogos experimentais, em particular o grupo em torno de Wilhelm Wundt (1832 – 1920), usaram de forma pragmática os mesmos métodos para criar a vertente da psicologia que viria a ser, em simultâneo, experimental e empírica. Igualmente relevante é o trabalho de Hermann von Helmholtz (1821 – 1894) que, tal como Fechner e Wundt, pertenceu à Universidade de Leipzig. Apesar do seu enorme contributo em diversas áreas, os mais relevantes referem-se à percepção visual do espaço, à “matemática do olho”, algumas pesquisas sobre a visão a cores ou, ainda, sobre a percepção do som.

Não é ousado, então, considerar que esta linha pioneira teve uma repercussão directa na psicofísica moderna.

2.2 O Cérebro Humano

Tido como um dos sistemas mais complexos que existem, o cérebro humano reunir um enorme potencial ainda por explorar. É, do ponto de vista anatómico, dividido em quatro zonas: córtex cerebral, cerebelo, hipotálamo e tálamo. Das anteriores, a mais relevante para um sistema BCI é o córtex cerebral, estruturado segundo dois hemisférios (esquerdo e direito), idênticos fisiologicamente e ligados entre si por uma região designada corpo caloso. Cada hemisfério controla o lado oposto do corpo, mas existem funções desempenhadas maioritariamente por um só; apesar desse facto, a sua plasticidade permite, por exemplo, que ficando um dos hemisférios seriamente danificado numa fase inicial da vida, o outro possa assumir as funções perdidas[30][31] ⁵.

Do ponto de vista funcional, o córtex cerebral está dividido em várias zonas (Fig. 2.2), de acordo com a função que é desempenhada, sendo este mapeamento essencial para estabelecer uma correspondência entre a actividade eléctrica lida e a tarefa mental, ou motora, executada.

O cérebro humano é constituído por milhares de milhões de células nervosas, também conhecidas por neurónios. Cada uma delas (Fig. 2.3), apresenta dendrites (do inglês, *dendritic tree*), um corpo celular (ou *soma*) e um axónio⁶ que se liga a várias dendrites de outras células; a esses contactos chama-se sinapses. Acresce a esta complexidade o facto de cada neurónio estar associado a várias células gliais, capazes de auxiliar no processo de transmissão de informação[32].

De um ponto de vista funcional, ainda que o modelo que se segue não seja em alguns casos rigoroso[33], considera-se o neurónio como o análogo biológico de uma unidade de processamento binária simples. As respectivas dendrites são uma espécie de canais de entrada, e cada neurónio calcula uma soma ponderada dos sinais provenientes de axónios de outros neurónios. O resultado dessa operação é ‘guardado’ nas sinapses, podendo ser de carácter estimulador ou inibidor, e determina,

⁴Fechner acabaria por passar grande parte do tempo que lhe restou lutando contra estes adversários, reais ou imaginários, publicando dois volumes (1877 e 1882) onde critica a resistência à inovação filosófica na Alemanha Imperial.

⁵Esta capacidade é conhecida como função vicariante

⁶Do inglês, *axon*, tem comprimentos que variam desde 100µm até 1m, no caso dos nervos periféricos na direcção dos músculos das pernas.




Figura 2.2: Mapeamento Funcional do Córtex Cerebral Humano (Fonte: www.scienceblogs.com)




Figura 2.3: Representação de Neurónios (Fonte: <http://www.sobiologia.com.br>)

caso a soma ultrapasse um dado limiar, a ocorrência de um salto de potencial no axônio, único canal de saída. Nessa situação, o neurónio diz-se em disparo (em inglês, *firing*). Esta organização, aliás, inspirou o nascimento de um campo da Inteligência Artificial – as Redes Neurais Artificiais (*Artificial Neural Networks*, ANN) – que procura fazer modelação cognitiva.

É uma função biológica importante do cérebro gerar comportamentos que promovam o bem-estar. O controlo desse comportamento pode ser feito por activação muscular ou segregação química, como o caso de hormonas. Mesmo organismos unicelulares estão aptos a extrair informação do ambiente e reagir em resposta[34]. As esponjas marinhas, que não possuem um sistema nervoso central, são capazes de movimentos coordenados e locomoção. Em vertebrados, a medula espinal contém circuitos neuronais capazes de gerar reflexos, e também padrões de movimento simples[35], como nadar ou caminhar[36]. No entanto, o controlo comportamental mais sofisticado, com base em informação sensorial complexa, requer as capacidades de integração de informação de um cérebro centralizado.

2.2.1 A Neurofisiologia do Movimento

A execução de um movimento motor, desde o simples pegar num copo até à execução de uma peça de piano, envolve um conjunto de etapas sequenciais que processam parâmetros envolvidos na acção, como por exemplo qual o material do copo, se está cheio e a que distância se encontra. Existe genericamente a conjugação de dois momentos: preparação e execução.

Essas etapas, embora intrinsecamente ligadas, são desencadeadas em zonas corticais distintas. Vários estudos[37][38][39][40][41] mostram que, quando a acção motora a ser executada é complexa e necessita de vários dados sensoriais, a sua preparação ocorre de forma inequívoca na área suplementar motora (SMA) e na área pré-motora (PMA) (Figura 2.4).




Figura 2.4: Áreas corticais responsáveis pela execução motora (Fonte: <http://brainconnection.positscience.com>)

Por outro lado, quando a informação necessária para a acção motora é apenas de origem visual, a área que demonstra maior activação é o Córtex Parietal Posterior (PPC) [42][43]; um exemplo de uma acção motora deste tipo é a escolha racional entre dois objectos, quando nenhuma instrução é dada ao sujeito. Após a preparação do movimento, o resultado é um ‘plano’ da acção a ser executada, e a área que o põe em prática é o Córtex Motor Primário (M1) [37][44].

A área M1 está subdividida em zonas associadas ao controlo específico de cada parte do corpo humano. É interessante verificar que zonas responsáveis por acções motoras de maior precisão, como o caso da mão, dedos ou língua têm uma maior área dedicada, comparativamente a outras áreas do corpo fisicamente maiores. A essa representação “adulterada” do corpo humano chama-se em medicina *homunculus* motor (Fig. 2.5). A partir da área M1 são enviados os impulsos eléctricos, através do tracto cortico-espinal, até à proximidade dos músculos, os responsáveis pela execução da acção motora previamente planeada.

2.2.2 A Imaginação Motora

A imaginação motora é o processo inerente à preparação e planeamento de um movimento, partilhando dessa forma o mesmo agrupamento neuronal que a execução. A activação cortical depende especificamente do tipo de imaginação motora praticada, a qual, nos últimos anos, tem sido dividida conceptualmente em três tipos: representação visual, simulação e observação de uma acção motora.

A imaginação motora baseada na simulação de um movimento está ligada à reactivação cinética em memória de um movimento previamente executado[37]. Neste processo, efectua-se a preparação do movimento da mesma forma que no caso da execução motora, mas sem efectuar a acção real.




Figura 2.5: Homunculus Motor (Fonte: <http://www.harmonicresolution.com/>)

A representação visual de uma acção motora é a descrição visual de um movimento previamente executado. De notar que, ao contrário da simulação, esta representação não implica um reconhecimento cinético da acção, mas apenas a sua visualização, enquanto modelo mental de uma execução motora.

Em geral, observar uma acção motora divide-se em duas fases: reconhecimento e percepção. Uma tarefa que ilustra bem o caso é a aprendizagem de um instrumento musical, onde o aprendiz tenta replicar a execução motora do professor[45]. Dependendo do tipo de imaginação motora praticada, as áreas corticais activas irão ser diferentes, tornando este tópico essencial no que toca aos sistemas BCI não-invasivos. Tais sistemas utilizam um conjunto de localizações para os eléctrodos, por norma independentes do utilizador e da tarefa mental efectuada.

Áreas Corticais Envolvidas

Como foi descrito anteriormente, dependendo do tipo de imaginação motora efectuada, esta irá activar diferentes áreas corticais. Para o caso da simulação motora, por se tratar em génese da preparação do movimento, irá activar predominantemente as áreas pré-motoras (SMA e PMC) e o córtex motor primário (M1)[37]. Embora ocorra activação no M1, estudos demonstram que esta representa apenas cerca de 30% face ao caso da execução real do movimento [46][47].

A observação e reconhecimento de um movimento tem sido reportada por activar um conjunto de neurónios situados no córtex pré-motor e no lobo parietal inferior. Essa rede, denominada neurónios espelho (do inglês *mirror neurons*), imita o comportamento observado, como se fosse o próprio sujeito a desenvolver a acção [48][49]. Este conjunto de neurónios está também ligado à imitação e aquisição da linguagem[50]. Por último, a imaginação motora baseada apenas na representação visual do movimento está intimamente ligada à activação bilateral do cerebelo, SMA e córtex parietal posterior[45].

2.3 Leitura de Sinais Cerebrais

Apesar do rápido progresso científico, muitos aspectos do cérebro permanecem um mistério. A operação de neurónios individuais e as sinapses são compreendidos em detalhe considerável, mas a forma como cooperam em conjuntos de milhares ou milhões tem sido muito difícil de decifrar. Métodos de observação, como electroencefalografias, mostram que as operações no cérebro são altamente organizadas; tais métodos não possuem, em contrapartida, a resolução suficiente para revelar a actividade individualizada de cada célula[51].

O uso de técnicas invasivas, como é o caso do ECoG (Electrocorticograma), traz sobre as não-invasivas a vantagem de uma aquisição de sinal mais rápida, resultando numa relação causa-efeito mais aparente. A desvantagem óbvia é a necessidade de recurso a cirurgia, por mais simples e fiável que seja, pelo que encontrar sujeitos de teste é também um grande obstáculo. Técnicas desta natureza acompanham a revolução dos dispositivos electrónicos e existem actualmente eléctrodos implantáveis de película fina, com baixo custo, capacidade de produção em massa [52] e tecnologias incorporadas para redução de ruído, filtragem, amplificação e mesmo circuitos de telemetria[53] que, em suma, podem ser altamente integrados e operam com energia mínima. São, por conseguinte, biocompatíveis e têm um período em funcionamento aproximado de um ano. Ainda assim, a sua utilização não pode ser considerada no contexto da investigação em curso, o que constitui um desafio adicional.

Em 1929, Hans Berger regista o primeiro EEG de um humano⁷, e descobre a existência de vários ritmos (comprimentos de onda), a que chama *Alpha* e *Beta*[54]. Berger demonstrou que a actividade eléctrica cerebral também podia ser lida no escalpe e chamou-lhe electroencefalografia (EEG). Foi esse o ponto de partida para o eclodir de técnicas não-invasivas de leitura de sinais cerebrais. Ainda assim, a difusão do EEG aconteceu apenas em 1958, com a definição do Sistema 10-20 para a colocação de eléctrodos no escalpe.

2.3.1 Electroencefalograma (EEG)

Um dispositivo de electroencefalografia, tal como o conhecemos hoje, pode demonstrar claramente a existência de padrões, nos sinais cerebrais, durante exercícios mentais e, ainda que uma das suas utilizações mais recorrente seja a detecção de focos neuronais responsáveis por fenómenos extremos de epilepsia, é possível, em particular, observar que regiões sofrem aumento de actividade quando certas acções (como o movimento da mão ou até a predisposição da mesma intenção) ocorrem.

Esta solução tem as suas desvantagens. A resolução espacial é baixa, no sentido em que a informação lida nos diversos eléctrodos apresenta elevado grau de redundância. É igualmente importante saber onde colocar os eléctrodos⁸.

Apesar dessa condicionante, a electroencefalografia está na base da generalidade dos sistemas BCI já implementados. Como exemplo, destaca-se o trabalho de Millán *et al.*[4] (2003), atribuindo a um paciente paralisado a capacidade de teleguiar com relativo sucesso um robô. O estudo, conduzido em “tempo real” (tempo de reacção próximo de 0,5 segundos), contou com a existência de três comandos (virar à esquerda, direita ou mover em frente), envolveu algumas horas de treino e culminou na navegação entre várias divisões com obstáculos, além de constituir a base anímica, por dizê-lo de alguma forma, a projectos subsequentes que aplicaram o mesmo paradigma a contextos de utilização diferentes.

⁷O sujeito de teste era o próprio filho.

⁸Esta tarefa pode ser melhor conseguida com recurso a outras técnicas, como *BOLD-fMRI*.

2.3.2 Outros Aparelhos: *Que viabilidade numa BCI?*

Além do recurso ao registo EEG, pensar em outra estratégia para a construção de BCIs não é, actualmente, uma opção acessível. As de natureza invasiva porque envolvem recurso a cirurgia. Entre as não-invasivas, faz-se a exposição que se segue.

- O magnetoencefalograma (**MEG**) baseia a leitura na detecção dos campos magnéticos gerados pelas actividade eléctrica. Permite assistir os cirurgiões na detecção de patologias e, no campo da investigação, é importante para determinar a função de várias partes do cérebro. Enquanto BCI, não é viável porque necessita de supercondutividade[55] e, por isso, opera a um custo muito elevado;
- Os dispositivos **PET** (*Positron Emission Tomography*) e **SPECT** (*Single Photon Emission Computed Tomography*) conseguem a leitura com recurso a técnicas de imagiologia nuclear. Como tal, requerem a inalação ou ingestão de substâncias radioactivas[56], cuja emissão é depois detectada, permitindo uma reconstrução 3D fiel do fluxo dos isótopos. São aparelhos de grandes dimensões, também muito dispendiosos;
- A técnica **TMS** (*Transcranial Magnetic Stimulation*) está pensada para estimulação (ou inibição) de certas zonas cerebrais. Estuda a funcionalidade e condutividade dessas zonas, quando sujeitas a uma variação abrupta de um campo magnético; as ínfimas correntes geradas são depois medidas[57][58]. Como BCI não pode ser usada, já que o estímulo é externo e não pertence ao sujeito;
- Por último, surge a mais importante em utilização clínica: a **fMRI** (*functional Magnetic Resonance Imaging*). É um tipo especializado de imagiologia baseado em ressonância magnética, que mede a resposta hemodinâmica (mudanças no fluxo sanguíneo) relacionada com actividade neuronal no cérebro ou na medula espinal, em humanos ou animais. É uma das mais recentes formas de neuroimagiologia e, desde o início dos anos 1990s, tem dominado esse campo. Para isso contribuem o baixo nível de invasão, a ausência de exposição à radiação e a sua relativa disponibilidade no mercado. Enquanto BCI, torna-se grande e dispendiosa, embora o principal problema seja o atraso de alguns segundos introduzido entre o estímulo/acção e respectiva leitura; ainda assim, neste domínio é utilizada como método complementar para determinar qual a melhor localização dos eléctrodos [59], pois tem a grande vantagem de possuir resoluções próximas de $1mm^2$.

2.4 Aquisição de Sinais EEG

2.4.1 Actividade Rítmica Cerebral

A actividade rítmica cerebral é classificada de acordo com a sua frequência, amplitude, forma e local de origem. O significado do registo electroencefalográfico varia de acordo com a idade do utilizador, estado de alerta, cansaço intelectual e morfologia do crânio.

O córtex cerebral é constituído por cerca de 30^{10} neurónios (divididos em cinco tipo de células nervosas) das quais 65 a 75% estão orientadas perpendicularmente à superfície. A actividade rítmica cerebral captada à superfície é originada primordialmente por estas células.

O sinal EEG é tipicamente descrito em termos de actividade (1) rítmica e (2) transitória. A actividade rítmica é dividida em bandas de frequência. Em algum sentido, tais bandas são apenas uma questão de nomenclatura, mas a sua definição provém das observações feitas, que demonstram

que determinada actividade, como uma dada gama de frequências, mostra padrões na distribuição no escalpe ou alguma significância biológica.

A maioria dos sinais observados no escalpe pertence à gama de 1 a 50 Hz pelo que, ao nível da frequência, os ritmos cerebrais podem ser divididos genericamente em cinco classes: *delta*, *theta*, *alpha*, *beta* e ondas *gamma*.

Ritmos *Delta*

É a banda até aos 4 Hz (Figura 2.6). São as ondas mais lentas, e tendem a ser as maiores em amplitude. São vistas normalmente em adultos, durante o sono profundo, e em bebés. Em adultos, ocorrem predominantemente no córtex frontal (FIRDA - *Frontal Intermittent Rhythmic Delta*), e em crianças no córtex occipital (OIRDA - *Occipital Intermittent Rhythmic Delta*).




Figura 2.6: Ritmos *Delta*

Ritmos *Theta*

Na gama 4–7 Hz (Figura 2.7), estes ritmos encontram-se em crianças mais novas, e podem ser vistos como manifestações de sonolência ou excitação em crianças mais velhas e adultos; estão igualmente reportados durante a meditação[60], relaxamento ou estados creativos. Têm a sua origem no tálamo.




Figura 2.7: Ritmos *Theta*

Ritmos *Alpha*

Foi a primeira actividade rítmica cerebral observada[54] (Hans Berger), e diz respeito à gama 8–12 Hz (Figura 2.8). Pode ser encontrada:

- Nas regiões posteriores do escalpe, em ambos os hemisférios, tendo maior amplitude no lado dominante⁹. Estes ritmos são fortemente reduzidos fechando os olhos, ou mediante relaxamento, e desaparecem durante o sono profundo.

⁹Esta actividade rítmica é também conhecida como “posterior basic rhythm”, “posterior dominant rhythm”, ou ainda “posterior alpha rhythm”. Em crianças mais novas é, de facto, mais lento que 8 Hz (pelo que nesse caso, tecnicamente, pertencem à banda *theta*).

- Preponderantemente, no córtex motor e sensoriomotor. Esta categoria localizada de ritmos *alpha* (Fig. 2.9) é designada por ritmos *mu* e, por base, está correlacionada com estados de repouso do cérebro. As modificações sofridas nos ritmos *mu* — supressão e ampliação — têm, na maioria dos casos, origem em eventos sensoriomotores, como é o caso da observação de movimentos e sua preparação[61][62][63][64].
- No lóbulo temporal. Este ritmo não mostra relação com o *alpha* posterior ou com o *mu* central, pelo que é vulgarmente designado por “*third-rhythm*”. Na presença de um crânio com espessura normal, não são detectáveis no escalpe[65]. A sua função permanece pouco clara[66].




Figura 2.8: Ritmos *Alpha*




Figura 2.9: Ritmos *mu*

Ritmos *Beta*

Beta é o grupo de frequências compreendido em 12–30 *Hz* (Figura 2.10), visto nos dois hemisférios em distribuição simétrica, e mais evidente no lóbulo frontal, ainda que também se verifique na região parietal.

Normalmente distinguidos em três sub-bandas, β_1 (13–18 *Hz*), β_2 (18–24 *Hz*) e β_3 (24–30 *Hz*), com origens distintas, mas globalmente associadas ao processamento de informação exterior, resolução de problemas ou tomada de decisões; como tal, estão presentes em qualquer comportamento motor[62] e são, em geral, atenuados durante a execução dos mesmos[67].

Os de baixa amplitude, com múltiplas frequências (que inclusive variam no tempo), estão associados com pensamentos activos ou introspectivos. Fazem, assim, parte da concentração mental activa. A ocorrência de ritmos *Beta* numa gama dominante de frequências está, por outro lado, ligado a várias patologias ou ao efeitos de certas drogas, especialmente benzodiazepinas. Podem estar ausentes em áreas corticais danificadas e são o ritmo dominante nos pacientes, de olhos abertos, em estados de alerta ou ansiedade.

Ritmos *Gamma*

Pensa-se que intervêm na ligação de diferentes populações de neurónios, em redes cujo propósito é realizar uma certa função, cognitiva ou motora. Estão relacionados com processos mentais de complexidade elevada como é a consciência e percepção, ocorrendo desde os 30*Hz* até ao




Figura 2.10: Ritmos *Beta*

limite da banda determinada pelo filtro aplicado ao EEG (Figura 2.11). Suspeita-se que sejam os ritmos cerebrais que contêm a maior quantidade de informação; no entanto, poucos avanços significativos foram ainda feitos na sua interpretação.




Figura 2.11: Ritmos *Gamma*

Na Tabela 2.1 ficam condensados os aspectos referidos nesta secção.

2.4.2 Atenuação e Dispersão

Existem três membranas (meninges) a envolver o cérebro e a medula espinal; desde o crânio até ao cérebro, são elas: (1) *dura matter*, a mais rígida entre elas, (2) *arachnoid*, assim chamada por ter um aspecto ramificado, e (3) *pia mater*, delicada e altamente vascular.




Figura 2.12: Representação das três meninges que envolvem o cérebro humano
(Fonte: Mayo Foundation for Medical Education and Research)

Tipo	Frequências	Localização	Normalmente ...	Patologicamente ...
Delta	Até 4 Hz	- Lóbulo frontal, em adultos; - Zona posterior do escalpe, em crianças; - Ondas de elevada amplitude.	- Em adultos, durante sono profundo; - Em crianças.	- Lesões subcorticais; - Lesões difusas; - Hidrocefalia encefalopática metabólica ("cabeça de água"); - Lesões profundas, na linha média.
Theta	4–7 Hz	_____	- Crianças mais novas; - Manifestações de sonolência ou excitação em crianças mais velhas e adultos; - Relaxamento.	- Lesões subcorticais localizadas; - Encefalopatia metabólica; - Desordens na linha média; - Alguns tipos de hidrocefalia.
Alpha	8–12 Hz	- Regiões posteriores da cabeça; - Maiores em amplitude no lado dominante; - No córtex motor e sensoriomotor, quando em repouso.	- Relaxamento/Reflexão; - Fechando os olhos.	- Coma.
Beta	12–30 Hz	- Nos dois hemisférios, com distribuição simétrica; - Mais evidente na região frontal; - Ondas de baixa amplitude.	- Alerta/Trabalho; - Pensamento activo, introspecção ou ansiedade; - Concentração mental activa.	- Benzodiazepinas.
Gama	30–100 Hz	_____	- Certas funções motoras ou cognitivas.	_____

Tabela 2.1: Ritmos cerebrais segundo a distribuição em frequências

Fisiologicamente, as correntes geradas no córtex cerebral são conduzidas até ao eléctrodo de aquisição começando pelas três meninges referidas, passando pelo fluido cefalorraquidiano, e no osso craniano, até ao escalpe (Fig. 2.12). Desta forma, verifica-se que o potencial originado numa determinada zona é disperso por uma área considerável do escalpe[68]. Essa dispersão tem duas consequências relevantes:

- O sinal é fortemente atenuado, pelo que o ruído nele presente tem uma importância largamente superior à desejável;
- Um dado eléctrodo contém informação proveniente não só do foco em consideração, como também de várias outras zonas excitadas.

2.4.3 Artefactos

Os sinais eléctricos detectados no escalpe por electroencefalografia, mas cuja origem é não-cerebral são vulgarmente designados de artefactos. Os dados EEG estão quase sempre contaminados por tais artefactos.

A sua amplitude pode ser muito elevada, quando comparados à amplitude dos sinais corticais de interesse. Essa é uma das razões pela qual se requer uma experiência considerável na análise clínica de sinais EEG.

2.4.3.1 Artefactos Biológicos

Alguns dos artefactos biológicos têm como origem:

- Movimentos oculares ou piscar de olhos, detectáveis por um electroculograma (**EOG**);
- O Coração. São visíveis num electrocardiograma (**EKG**);

- Activação Muscular, medida por electromiografia (**EMG**). No caso da língua, são conhecidos como *Glossokinetic artifacts*.

Nos olhos, são causados pelas diferenças de potencial entre a córnea e a retina, que é bastante grande em relação aos potenciais cerebrais. Quando o olho está completamente parado, estes artefactos não afectam o EEG, embora existam sempre movimentos pequenos ou reflexivos, que geram um potencial detectado na zona do escalpe a eles próxima. O piscar de olhos tem um movimento reflexivo característico, detectável no EEG e conhecido como fenómeno de Bell. Estão presentes, habitualmente, nas bandas *theta* (4—7 *Hz*) e *alpha* (8—12 *Hz*). Alguns destes artefactos são úteis, ao nível do EEG, na detecção de variações no estado de alerta, sonolência ou sono.

Os artefactos EKG são bastante comuns e podem ser confundidos com os potenciais de células das membranas, em fase de excitação¹⁰. Por causa disto, os sistemas EEG modernos incluem um canal EKG e permitem, por exemplo, identificar arritmias cardíacas, cujo diagnóstico diferencial é útil para rastrear outro tipo de desordens.

Os artefactos associados à língua são causados pela diferença de potencial, entre a base e a ponta da mesma. Podem contaminar o registo EEG, especialmente em desordens parkinsonianas.

2.4.3.2 Artefactos Ambientais

Em adição aos artefactos gerados pelo corpo humano, muitos outros, de origem externa, entram em consideração. Entre eles:

- O movimento do paciente, ou o simples arranjo dos eléctrodos, pode levar a que estes se soltem, originando variações momentâneas na impedância de um dado eléctrodo;
- Os sistemas de referência (*grounding*) típicos, que introduzem artefactos significativos de 50 *Hz* ou 60 *Hz*, dependendo da frequência da rede de alimentação local.

2.4.3.3 Correção de Artefactos

Recentemente, técnicas de decomposição dos sinais têm sido usadas para corrigir ou remover registos EEG contaminados por artefactos. Tais técnicas tentam decompor esses sinais num dado número de componentes subjacentes. Existem muitos algoritmos de separação, por norma assumindo diversos comportamentos ou naturezas para um mesmo EEG. Espera-se, de um método em particular, a capacidade de permitir a reconstrução dos sinais originais, anulando ou minimizando o peso das componentes indesejadas.

2.4.4 Disposição dos Eléctrodos

Como já referido, o sinal adquirido é alvo de dispersão espacial e de atenuação em amplitude. Devido a estas condicionantes, a colocação espacial dos eléctrodos e sua combinação torna-se relevante. Técnicas desta natureza correspondem, em alguns casos, a filtragens espaciais e permitem isolar, de alguma forma, a actividade cerebral localizada. Parâmetros como o número de eléctrodos utilizado, ou o cálculo matemático envolvido no processamento de cada sinal, terão influência no desempenho global do sistema, a nível de processamento.

Apresentam-se duas técnicas conhecidas para filtragem ou re-referenciação dos sinais recolhidos.

¹⁰Do inglês, *spike activity*.

2.4.4.1 Common Average Reference (CAR)

Utiliza-se todo o *setup* de eléctrodos disponível. Desta forma, é subtraída ao canal de interesse a média de todos os outros. Esta técnica permite eliminar componentes que estão presentes na maior parte dos eléctrodos, e que não assumem interesse na generalidade das aplicações BCI. Existem variados sistemas para posicionamento de eléctrodos (Figura 2.13-C). Um montagem possível pode ser a baseada no Sistema Internacional 10-20 (Figuras 2.13-A,B). Em função do propósito da análise em causa, técnicas mais simples, como usar um só canal como referência, são também frequentemente adoptadas.

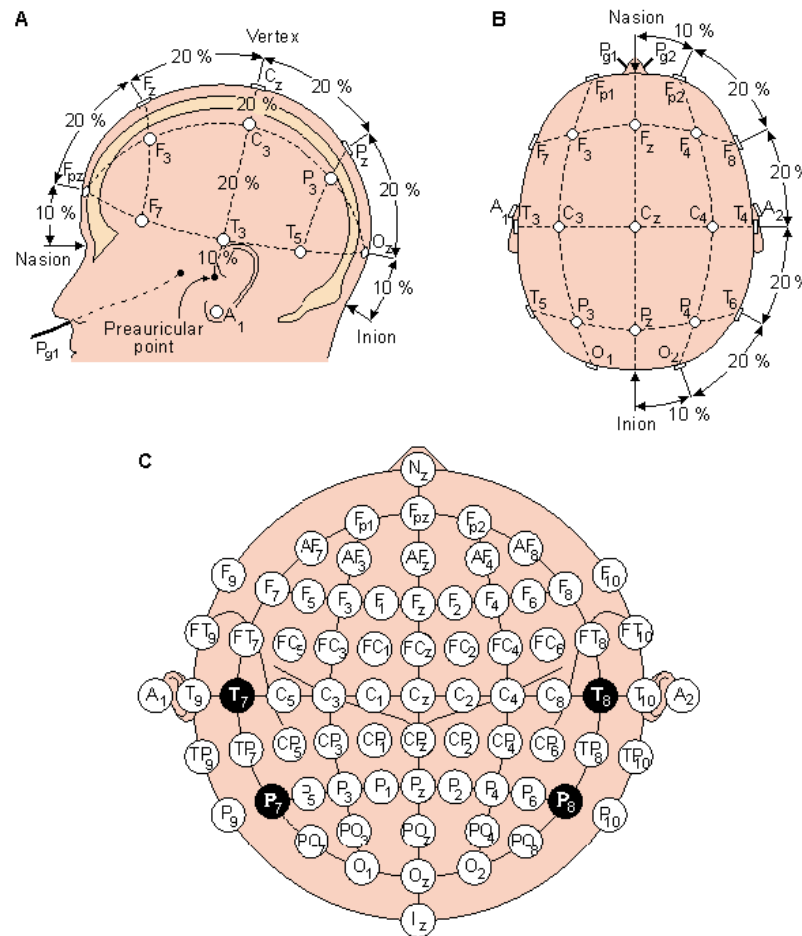


Figura 2.13: Sistemas para posicionamento dos eléctrodos no escalpe humano

2.4.4.2 Montagem Laplaciana

Um método para aumentar a resolução espacial do EEG é utilizar uma montagem Laplaciana. Tal como no caso da montagem CAR, esta filtragem espacial funciona como um filtro passa-alto, acentuando a actividade da zona determinada espacialmente pelos eléctrodos e diminuindo a actividade distribuída proveniente de focos de excitação distantes. Dependendo da zona em questão ser maior ou menor, pode-se utilizar a Small ou Large Laplacian; em qualquer dos casos, a zona referente ao perímetro determinado pela colocação de uma combinação particular de eléctrodos será acentuada[18].

2.5 BCIs baseadas em sinais EEG

Um sistema BCI (Fig. 2.14) é por definição multidisciplinar, congregando áreas tão diversas como neurologia, psicologia, processamento de sinal, reconhecimento de padrões, ciências da computação e, no caso do actual projecto, realidade virtual. Conceptualmente, podemos dividi-lo em quatro grandes áreas:

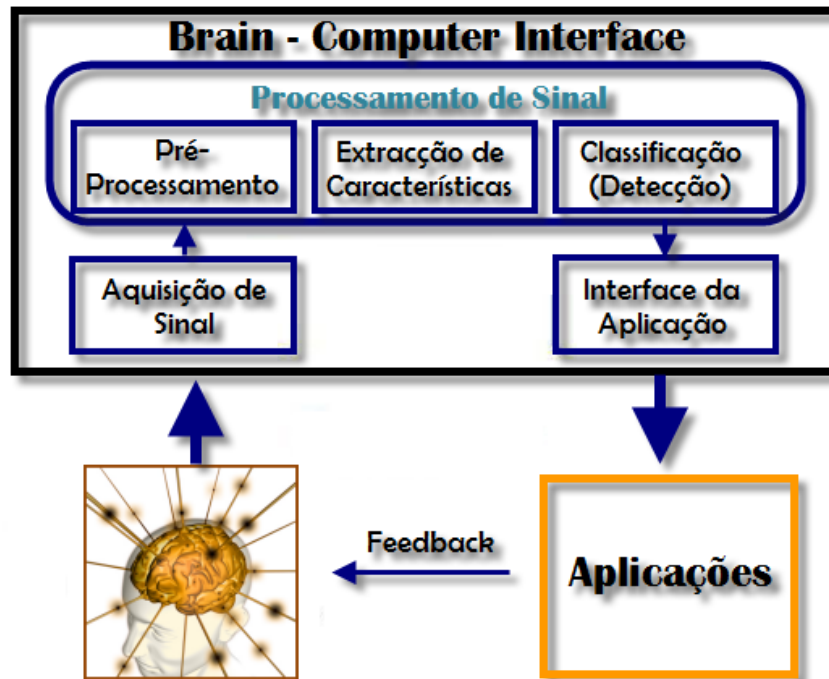


Figura 2.14: Multidisciplinaridade de um sistema BCI

Aquisição de Sinal:

- Medições da actividade rítmica cerebral através dos eléctrodos do EEG. Outras técnicas de aquisição podem ser utilizadas, como é o exemplo da fMRI[2] ou eléctrodos intra-corticais[69]. O sinal medido é digitalizado e ampliado de forma a poder ser utilizado pelos restantes blocos do sistema.

Extracção de Características:

- Este bloco já inclui o pré-processamento aplicado ao sinal adquirido, que passa pela filtragem da banda de interesse e da remoção dos artefactos;
- Para garantir características o mais distintas possível, ao sinal pré-tratado são aplicadas técnicas de filtragem espacial, análise espectral e medição de amplitudes no tempo, entre outras;

- Na forma mais simples de extracção de características, é escolhida uma banda de frequência através da qual se comparam as amplitudes da DEPs;
- Para cada tarefa mental com as suas particularidades, é escolhido o conjunto de sub-blocos que se adequa melhor, isto é, que fornece para duas tarefas mentais diferentes o conjunto de características que permite a maior taxa de separabilidade no classificador.

Classificação:

- O classificador tem como entrada as características extraídas do sinal (*features*), e apresenta como saída os comandos para o dispositivo de saída;
- Um classificador de um sistema BCI contém tipicamente duas a cinco classes (limitadas pelas características presentes no sinal) e varia de um simples modelo linear a uma rede neuronal complexa que necessita de treino;
- Um classificador pode também ser do tipo determinístico ou estatístico, com base na probabilidade de cada tarefa mental.

Dispositivo de Saída:

- Os dispositivos de saída dividem-se em dois tipos segundo a sua função, feedback para o utilizador ou a aplicação concreta que se pretende controlar. Em alguns casos, resume-se apenas a um bloco, como é o caso do controlo de um cursor, ou da escolha de uma letra no ecrã. Para o treino da auto-regulação dos ritmos cerebrais, utiliza-se um bloco em que visualmente se mostra qual a classificação obtida;
- Dependendo do número de classes permitidas, será maior ou menor, os comandos que o dispositivo de saída permite executar.

2.5.1 Paradigmas de Operação

Cada bloco anteriormente descrito será configurado de acordo com o paradigma de operação que melhor adequa ao tipo de sistema BCI as respectivas tarefas mentais. Pode então estruturar-se de acordo com as seguintes características:

- **Operação no tempo**

Síncrono/Assíncrono:

Se o sistema BCI actuar mediante o livre-arbítrio do utilizador, sem serem estabelecidos instantes em que a aquisição é possível, diz-se que o sistema é assíncrono. Se por outro lado, o sistema depender de um intervalo no tempo, no qual são analisados os ritmos originados diz-se que o sistema está a funcionar de forma síncrona. Os sistemas assíncronos permitem, naturalmente, maior liberdade ao utilizador.

- **Actividade Eléctrica Cerebral Analisada**

Potenciais Evocados (Event Related Potentials - ERP):

Potenciais Evocados dizem respeito ao registo do EEG que se deve a uma resposta a um evento ou estimulação. Podem ser divididos em Exógenos ou Endógenos. Os primeiros ocorrem até cerca de 100 *ms* após a estimulação suceder e dependem das propriedades da estimulação (ruído, intensidade, ...). Potenciais endógenos ocorrem 100 *ms* após a estimulação, e dependem das características comportamentais relacionadas com o estímulo em si. Um exemplo de um sistema baseado nos potenciais evocados endógenos é o P300.

Potenciais Espontâneos:

Na ausência de estímulos, o cérebro humano apresenta uma actividade rítmica que corresponde aos seus desejos, motivos e iniciativas. A maioria dos sistemas BCI que utilizam este paradigma, escolhem a banda dos 8 aos 30 *Hz*, agrupando os ritmos *mu* e *beta* para análise. Um exemplo da aplicabilidade dos potenciais espontâneos são os sistemas ERD (*Event-Related Desynchronization*) e ERS (*Event-Related Synchronization*).

Os sistemas baseados na detecção da dessincronização dos ritmos cerebrais (ERD), focam preferencialmente os ritmos *mu*; este facto deve-se à supressão dos ritmos *mu* quando executadas tarefas mentais que visam a imaginação/realização motora. Para se analisar a dessincronização dos ritmos cerebrais, é gravado, anteriormente ao teste *online*, o sinal que irá ser comparado com o originado no decorrer da experiência. Este sinal é designado de *baseline* e consiste num sinal na banda *mu* que é originado, através de tarefas mentais que implicam o “repouso” da zona cortical que se pretende excitar com as tarefas mentais propostas.

- **Colocação dos eléctrodos**

Um sistema BCI classifica-se como invasivo se forem utilizados eléctrodos intra-corticais, ou não invasivo se a colocação dos eléctrodos não exigir nenhum tipo de cirurgia sendo a sua colocação de forma muito mais fácil. Como é simples de verificar, a aplicabilidade de um sistema baseado em eléctrodos intra-corticais torna-se limitada, no entanto as melhorias relacionadas com a qualidade do sinal e a sua relação sinal-ruído são evidentes.

- **Modo de Funcionamento**

Diz-se que um sistema funciona em modo *online* se todo o processamento se der em tempo real, ou seja, existe um feedback contínuo ao utilizador. É indicado este funcionamento para tarefas que exijam uma resposta imediata, como é o caso da navegação em ambientes gráficos.

2.5.2 Casos de Sucesso

Nesta secção faz-se uma análise sobre os centros de investigação mais relevantes na área do BCI e seus sistemas implementados até à data.

2.5.2.1 Wadsworth Center

Jonathan Wolpaw e seus associados deram início ao desenvolvimento de um sistema BCI em 1986. Tal sistema[70][5][71] tinha, como paradigma, o controlo dos ritmos cerebrais *mu* e *beta*. Os sinais eram adquiridos através de 64 eléctrodos e convertidos a 128Hz , com excepção de *C3* e *C4*, convertidos a 196Hz . Utilizou-se uma filtragem espacial do tipo CAR e as características para classificação foram determinadas através de um modelo auto-regressivo, sendo posteriormente classificadas por intermédio de uma equação linear.

O objectivo deste sistema era o controlo de um cursor num ecrã, deslocando-o desde a posição central até à posição superior, através de 94 passos de classificação. Outro *output* utilizado consistiu na resposta a várias perguntas colocadas, através da colocação do cursor em duas possíveis escolhas presentes no ecrã, uma negativa outra positiva (“Sim”, “Nao”).

2.5.2.2 Graz University

Desde 1991, altura em que Pfurtscheller e o seu grupo de investigação iniciaram o projecto “*Graz Brain-Computer Interface*”, que tem desenvolvido vários[1] protótipos de um sistema BCI. Embora com características diferentes, todos se baseavam no paradigma da sincronização/dessincronização dos ritmos *mu* (ERD e ERS). Como tarefa mental era utilizada preferencialmente a imaginação motora.

O sistema implementado é síncrono, e a aquisição efectuada através de 29 eléctrodos, convertidos a 256Hz . A extracção das características é feita em cinco bandas de frequência (7–10, 10–13, 16–20, 20–24 e 24–30 Hz), através de um filtro *Butterworth* de quinta ordem, na janela temporal de 4 a 8 segundos após o *beep* que dá início ao treino. Para a classificação, utilizou-se um modelo estatístico designado *Hidden Markov Model*. Sujeitaram-se os utilizadores a um número de tarefas cada vez maior e concluiu-se, como seria de esperar, uma diminuição na taxa de sucesso com o aumento do número de tarefas a efectuar.

2.5.2.3 Millán BCI: *Brain-Actued Interaction*

A investigação[3][72] efectuada pelo Professor José del R. Millán mostra algum paralelismo com o presente projecto. Ainda que o sistema *Brain-Actued Interaction* tenha como objectivo controlar um robô, as técnicas envolvidas no processamento de sinais apresentam algumas similaridades.

Para além da vertente de controlo de um robô, o sistema BCI implementado pretende possibilitar a tarefa de escrita num teclado virtual, mostrado num ecrã.

Foram utilizados oito eléctrodos: *F3*, *C3*, *P3*, *Pz*, *Cz*, *F4*, *C4* e *P4*. As tarefas mentais utilizadas foram: imaginação motora da mão direita, imaginação motora da mão esquerda e associação de palavras. Desta forma, configuram-se quatro estados possíveis no caso do controlo de um robô: esquerda, direita, frente e parado.

No caso do teclado virtual, este é inicialmente dividido em três zonas, cada uma correspondendo a uma tarefa mental. Quando uma zona é seleccionada, descartam-se as outras duas, e a que resta é sucessivamente dividida em três zonas sub-zonas. Assim, ao fim de três passos, é possível escolher uma letra entre 26 possíveis. Em relação à extracção das características, utilizou-se o método ERD para os ritmos *mu* e *beta*, sendo considerada a banda de frequência dos 8–30 Hz e a relativa diferença de amplitude entre os sucessivos cálculos da densidade espectral de potência (DEP), para sucessivas janelas de tempo. O classificador usado é do tipo estatístico (Gaussiano), e foi treinado para discriminar um entre quatro estados possíveis, ligados às tarefas mentais mencionadas anteriormente.

Capítulo 3

O Problema do Controlo de uma BCI

*You have to have conviction and completely question
everything and anything you do.
No matter how much you study, no matter how much you know,
the side of your brain that has the smarts
won't necessarily help you in making art.*

– Maya Lin

Preparar uma BCI implica uma dose considerável de planeamento. Assim, o conhecimento adquirido, apresentado no Capítulo 2, revelou-se fundamental. Em particular, porque ajudou a definir a linha de investigação e, sempre que necessário, permitiu validar (ou refutar) as opções testadas. Foram, até ao momento, compreendidas as dificuldades aliadas a um projecto desta natureza, em aspectos que vão desde os níveis de entropia nos sinais biológicos adquiridos, passando pelo esforço em recolher a informação mais relevante ao contexto de estudo, até à derradeira escolha de um paradigma em que seja viável a sua implementação.

Ao mesmo tempo, este trabalho visa dar seguimento ao caminho já iniciado em anos anteriores com o desenvolvimento da *IEETA-BCI* cujo paradigma de operação é baseado na detecção e classificação de alterações no sinal de EEG relacionadas com tarefas de imaginação motora. Mais concretamente, ao longo do trabalho procurou-se explorar um conjunto de ferramentas e métodos relacionados com o problema do controlo de uma BCI. A maioria das BCIs actuais usa uma combinação de duas aproximações: (1) o treino do utilizador que aprende a manipular a actividade de interesse e a adquirir - até certo ponto - mecanismos de controlo voluntário da sua actividade cerebral e (2) a adaptação dos algoritmos a um utilizador para detecção de sinais cerebrais relevantes com base em algoritmos de aprendizagem automática.

Este capítulo descreve os esforços desenvolvidos nestas duas componentes. A primeira parte do trabalho é dedicada a aspectos de treino do utilizador, nomeadamente, ao desenvolvimento de ambientes de realidade virtual, em que o utilizador recebe informação visual sobre as alterações da sua actividade cerebral e acerca do seu desempenho. A segunda parte do trabalho, e talvez a mais relevante, relaciona-se com o estudo de algoritmos de aprendizagem automática que descodifiquem a actividade cerebral e se adaptem a um utilizador específico.

3.1 Ferramentas de Treino - Controlo Voluntário da Actividade Cerebral

Em experiências clínicas, a utilização do EEG tornou-se frequente por revelar a variação dos padrões cerebrais durante exercícios mentais e por determinar as regiões do cérebro que apresentam uma alteração na actividade quando ocorrem certas acções ou quando se verificam estímulos externos [38][44][73][1][41][48][61][64][47][37][43][45]. Ao contrário destas experiências, as BCIs constituem um novo desafio em que os utilizadores podem aprender a regular de forma voluntária a sua actividade cerebral (activar/desactivar) em zonas corticais específicas. Por exemplo, têm sido descritos na literatura estudos sobre a regulação dos potenciais corticais curtos (*slow cortical potentials*) ou dos ritmos sensório-motores [74][75][76][77].

Nesta linha de ideias, pretendia-se neste trabalho dar os primeiros passos na exploração de ferramentas de realidade virtual e a sua integração como mecanismo de realimentação na fase de treino da actividade cerebral. A fase de treino é considerada fundamental para melhorar a operação/controlo do sistema BCI baseada no paradigma da imaginação motora [78][79]. Ao integrar a tecnologia de realidade virtual pretende-se recriar ao máximo a percepção de realidade (espacial e temporal) por parte do sujeito. A interacção poderá ser realizada em tempo real com o uso de técnicas e de equipamentos computacionais que contribuem para a ampliação do sentimento de presença (“imersão”) na acção.

Neste contexto, os objectivos inicialmente traçados foram os seguintes:

- Analisar as potencialidades de bibliotecas gráficas e de processamento de imagem associadas à criação e navegação em ambientes virtuais;
- Desenvolver ferramentas computacionais dedicadas à criação de ambiente virtuais e à navegação nos mesmos;
- Interligação do processo de navegação no ambiente virtual ao sistema BCI. Tratando-se de módulos independentes, é necessário definir o protocolo que associa estados mentais com comandos de alto nível para navegação no ambiente virtual (*e.g.*, avançar, virar e parar).

De notar que a avaliação do potencial do treino da actividade cerebral do sujeito quando inserido num ambiente imersivo de realidade virtual não era um dos objectivos deste trabalho, sendo parte de outros em curso no IEETA. As próximas subsecções descrevem os ambientes gráficos de treino e teste concebidos, aptos a serem utilizados em contextos de treino.

Como afirmou[80] o famoso psicólogo americano James, há cerca de 100 anos, todos temos uma forte intuição sobre o significado da atenção:

“Everyone knows what attention is. It is the taking possession by the mind, in clear and vivid form, of one out of what seem several simultaneously possible objects or trains of thought. Focalization, concentration of consciousness are of its essence. It implies withdrawal from some things in order to deal effectively with others, and is a condition which has a real opposite in the confused, dazed, scatterbrained state...” (James, 1890, p. 403)

A ideia de atenção como um processo pelo qual os recursos mentais podem ser concentrados ou focados continua a ser tema de reflexão no estudo científico da atenção. Psicólogos e neurocientistas dividiram este conceito em três diferentes formas: baseada (1) no espaço, (2) no objecto ou (3) na característica.

Helmutz (1867) foi um dos primeiros a demonstrar[81], numa experiência controlada, mecanismos sobre como a atenção é direccionada no espaço. No estudo moderno da atenção, o paradigma *Posner*

(Posner,1980)[82] tem sido particularmente influente¹.

Na generalidade das operações com BCIs, os sujeitos de teste são convidados a sentar-se, descontrair e focar o seu treino na produção de comandos para a navegação. É expectável a detecção de dois/três estados mentais, conducentes a rotações ou avanços, requisitos indispensáveis à eficiência e flexibilidade de utilização. Se existir uma analogia natural entre os estados mentais e o tipo de *feedback*, a estratégia terá provavelmente mais sucesso, como no caso em que a imaginação motora de uma parte do corpo conduz à rotação (ou movimento) no mesmo sentido.

3.1.1 Ambiente de Aquisição/Calibração

O ambiente idealizado (Figura 3.2) permite dar instruções ao utilizador sobre três acções mentais pré-definidas, através da apresentação de setas “Esquerda”, “Direita” e “Frente”. Esta plataforma pode ser utilizada numa fase de treino sem *feedback*, utilizada para fazer as primeiras aquisições de dados EEG de um sujeito ou ainda em momentos de calibração, que tipicamente precedem os testes *online*. No primeiro caso, o ambiente informa o utilizador sobre a actividade mental a realizar e, no segundo, funciona como *feedback* na validação das acções mentais que o sujeito de teste executa mediante o seu livre arbítrio.

Quando existe uma intenção de controlo, é apresentado um *smile* verde e a barra de progresso mostrada ao fundo pretende fornecer uma métrica da intensidade/fiabilidade no reconhecimento da imaginação em causa. Em situações de ausência de intenção, o *smile* apresentado será amarelo e na presença de artefactos oculares ou musculares previu-se a utilização de um *smile* vermelho, acompanhado da mensagem “Relax!”.

Quando utilizado um ambiente gráfico virtual em experiências *online*, é razoável assumir a ocorrência de artefactos oculares. Para que o ambiente de aquisição (ou calibração) desenvolvido possa recriar essas condições, adicionou-se um aspecto de configuração adicional que permite o movimento repetitivo das setas, em alternativa às suas posições rígidas.

Este ambiente foi desenvolvido em C++, com o auxílio da ferramenta de desenvolvimento de ambientes gráficos Qt². Além de ser multi-plataforma, possui também várias aplicações de desenvolvimento rápido e integrado. Na Figura 3.1 mostra-se um estágio de desenvolvimento do software.

A actualização do ambiente é feita por comunicação remota, mediante um protocolo aplicacional que corre sobre canais TCP/IP. Nos pacotes recebidos vem codificado o tipo de *smile*, o tipo de seta e, sempre que aplicável, a certeza na detecção da imaginação efectuada (barra de “progresso”). O ambiente é depois ciclicamente actualizado em função da informação de controlo recebida.

3.1.2 Ambiente Gráfico Virtual

O ambiente gráfico de teste desenvolvido, descrito na presente secção, pretende ser uma base para a realização futura de experiências *online*. Poderá, especialmente, constituir um ambiente de realidade virtual, com recurso a dispositivos HMD (*Head Mounted Display*), mas deve também averiguar-se a existência de eventuais interferências electromagnéticas entre HMD e eléctrodos de aquisição EEG.

O cenário desenvolvido tem o formato de uma arena, e o utilizador tem uma perspectiva do ambiente na primeira pessoa. Na idealização de tal ambiente, houve a preocupação de desenvolver

¹Em particular, este paradigma tem sido utilizado para quantificar as falhas de atenção que ocorrem em pacientes com lesões no lóbulo parietal, levando à teoria de que os mecanismos de atenção espacial podem estar localizados no córtex parietal.

²Para mais informações, consultar <http://qt.nokia.com/products/developer-tools/>.

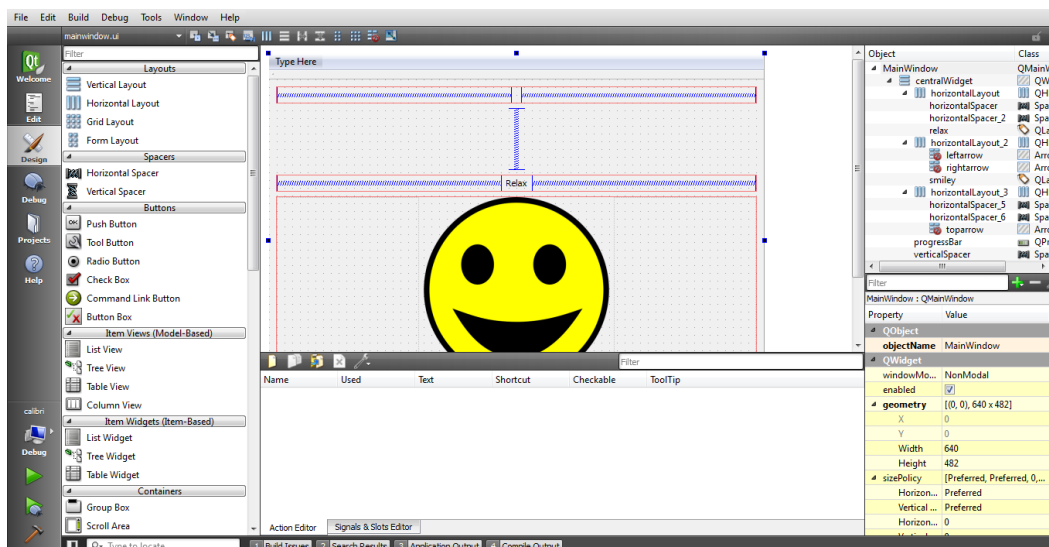


Figura 3.1: *Qt Creator* : Ferramenta utilizada no desenvolvimento do ambiente gráfico de treino e calibração




Figura 3.2: Quatro cenários distintos, para vários estados, na plataforma gráfica de treino (ou calibração) desenvolvida

uma interface minimalista e visualmente consistente, já que a introdução de cenários complexos para navegação pode desconcentrar mais o sujeito, por levar a uma sobrecarga da sua memória visual. Em todo o caso, foi adicionada, em benefício da usabilidade, uma interface na qual o utilizador tem acesso ao *status* do seu progresso. A missão, no ambiente projectado, será a recolha de um número limitado de objectos (cubos). Adicionalmente, dada a simetria da arena, são adicionadas fontes de luz e elementos que dão o relevo e perspectiva necessários à localização relativa do sujeito no “terreno”. As variáveis independentes guardadas em memória, para avaliação do desempenho, serão a quantidade de objectos recolhidos, bem como os instantes de tempo associados. O desafio estará também na duração limitada (configurável) da experiência.

Um último aspecto, talvez o mais importante do motor gráfico desenvolvido, tem a ver com a sua independência relativamente ao ambiente de processamento e decisão sobre os sinais EEG. No presente projecto, as ferramentas de tratamento de dados são descritas nas Secções 3.2.4.1 e 3.2.4.2. A sua interligação com o “mundo” virtual é feita enviando pacotes de instruções, por intermédio de

sockets TCP/IP. Se a carga computacional no processamento dos dados EEG for elevada, o protocolo de comunicação TCP/IP permite que o ambiente gráfico/virtual possa correr paralelamente em outro computador, o que constitui uma vantagem adicional.

Para que as acções mentais tenham um efeito contínuo no deslocamento dentro do mundo virtual, será necessário que o classificador produza e envie decisões a uma taxa superior ao *framerate* do ambiente, que corresponde a $25Hz$. Os valores de velocidade linear e angular definidos por defeito, respectivamente 1 metro/segundo e $\pi/4$ radianos/segundo, podem ser ajustados às necessidades, pelo que o protocolo nos comandos enviados contempla sempre um vector velocidade e a indicação do tipo de acção (deslocamento ou rotação). Dada a dificuldade actual em realizar experiências com BCIs usando mais que dois ou três estados mentais, os graus de liberdade que o protocolo permite serão certamente excessivos. Em todo o caso, usando, por exemplo, dois tipos de imaginação motora é também possível a deslocação efectiva no ambiente: uma para rotação, outra para avanço.

A Figura 3.3 regista duas capturas da arena modelada.



Figura 3.3: Ambiente virtual desenvolvido, com formato de uma arena

Enquanto auxílio à avaliação posterior do desempenho dos utilizadores no ambiente virtual criaram-se funcionalidades, em Matlab, que apresentam visualmente o trajecto efectuado. A exposição quantitativa das variáveis independentes antes referidas (objectos recolhidos e tempo associado) é também possível.

Na Figura 3.4 pode ver-se a quantidade de objectos recolhidos como função do tempo. As linhas verticais a laranja representam colisões com os limites (paredes) do mundo virtual. Para o efeito, esta *toolbox* acede aos registos de desempenho criados em memória pelo ambiente virtual.

Remete-se exposição dos recursos de software utilizados para as secções seguintes, que poderão ser consultadas para compreender, por exemplo, quais foram as ferramentas gráficas adoptadas. Apresentar-se-á também a fundamentação de tais escolhas.

3.1.2.1 Motor Gráfico *OGRE3D*

A indústria de jogos, em especial, deve a sua afirmação a ferramentas de produtividade que apresentam ao programador (ou equipa de programadores) uma linguagem gráfica de alto nível e compilam a solução baseadas na dependência em bibliotecas gráficas como *DirectX* ou *OpenGL*. Tais ferramentas são, por norma, muito caras e em nenhum caso universais, isto é, existem soluções dedicadas a modelar um cenário, outras para o desenvolvimento de objectos 3D que podemos incluir no cenário, outras ainda para aspectos como a Física ou interfaces gráficas de configuração adicionais.




Figura 3.4: Interface em Matlab, para registo dos detalhes de cada utilização no ambiente gráfico/virtual

Felizmente, podemos recorrer a soluções *freeware* e *open-source* com provas dadas e, entre elas, a plataforma de desenvolvimento *Ogre3D* (*Object Oriented Graphics Rendering Engine*) adquiriu notável sucesso, sendo considerado um dos melhores motores gráficos do momento. Com esta reputação, atraiu o interesse e colaboração de uma comunidade crescente de utilizadores, sendo hoje amplamente actualizada e suportada. Ainda que, no seu núcleo, colaborem dez *experts* na área, o motor gráfico não seria um potencial motor de jogos caso a comunidade não contribuísse com *Add-Ons* de Física, Som ou GUIs (*Graphic User Interfaces*), que poderão ser respectivamente *Ogrenewt*, *OgreAL* e *CEGUI*, entre outros.

Ao nível de programação, estruturação e compilação de código foi utilizado o *MS Visual Studio*®, por existirem binários pré-compilados, específicos a cada versão, no *site* oficial do motor *Ogre3D*. Adicionalmente, é necessário conhecimento ao nível de programação orientada aos objectos (*C++*), como também uma noção sobre a organização da própria estrutura do motor gráfico[83]. Tendo em conta o calendário destinado ao planeamento do presente projecto, as ferramentas escolhidas para o desenvolvimento do ambiente enquadraram-se, por terem favorecido a produtividade.

O “esqueleto” base de código é o projecto “Maze”, criado por (Hussen et al. 2006)[84], um ambiente virtual que assenta nas ferramentas de programação projectadas e destinado ao estudo de usabilidade em ambientes de realidade virtual e aumentada. As motivações para o fazer são várias:

- Os mecanismos relativos à física e som estão bem implementados (detecção de colisões, obstáculos, efeito gravítico e feedback audiovisual);
- O motor gráfico (*Ogre 3D*) contido permite a inclusão de diferentes cenários/ambientes e objectos 3D, desde que em formatos suportados;

- Nas palavras dos autores, a interface poderá ser “importante para o desenvolvimento futuro de aplicações que possam ganhar com estas tecnologias”.

3.1.2.2 Modelação de Objectos 3D

Para a criação de objectos a incluir no cenário, foi utilizada a ferramenta *Blender*® (Figura 3.5). O formato produzido pode depois ser convertido numa gama de vários outros, alguns compatíveis com o motor do *Ogre3D*. O intermediário para essa conversão poderá ser o *BlenderExporter*®, desenvolvido pela comunidade *Ogre3D.org*, capaz de produzir o formato – *mesh* – final desejado.




Figura 3.5: *Blender*: Ferramenta para modelação de objectos 3-D

Na construção do cenário, utilizou-se o conhecido modelador 3D *GtkRadiant*®, que opera com um formato próprio (*map*), depois convertido para a representação *bsp* (*Binary Space Partitioning*), usada em jogos como *Doom*, *Quake* ou *Half-Life*, e adoptada pelo *Ogre3D*. Uma alternativa encontrada, igualmente *freeware*, é o *QuArK*®. Capaz de operar directamente com ficheiros *bsp*, lida igualmente com arquivos *pk3*³. Pela sua versatilidade em formatos de entrada, constituiu a solução de modelação gráfica adoptada.

Nas Figuras 3.6 e 3.7 ilustra-se o trabalho da arena idealizada, em *QuArK*® e *GTKRadiant*®, respectivamente.

3.2 Aprendizagem Automática - Adaptação da Máquina ao Utilizador

Tipicamente, os sinais EEG são de elevada dimensionalidade. Os dados recolhidos correspondem a potenciais eléctricos, amostrados a uma taxa relativamente alta, que em função das necessidades pode variar entre valores típicos de 100 a 3000Hz. Além disso, o número de eléctrodos usados acrescenta, à partida, uma dimensão extra aos dados. Esta perspectiva, de tempo-espaco, fornece evidências sobre

³Na essência, ficheiros do tipo *pk3* são um conjunto de mais ficheiros, projectados para o jogo *Quake III* (actualmente distribuído de forma gratuita), reunidos em formato *zip* e contendo, além do mapa *bsp*, outros dados referentes a texturas ou *scripts* a aplicar ao cenário. É, também ele, um formato suportado pelas bibliotecas do *Ogre3D* e, além dessa potencialidade, permite a criação de objectos 3D directamente no cenário

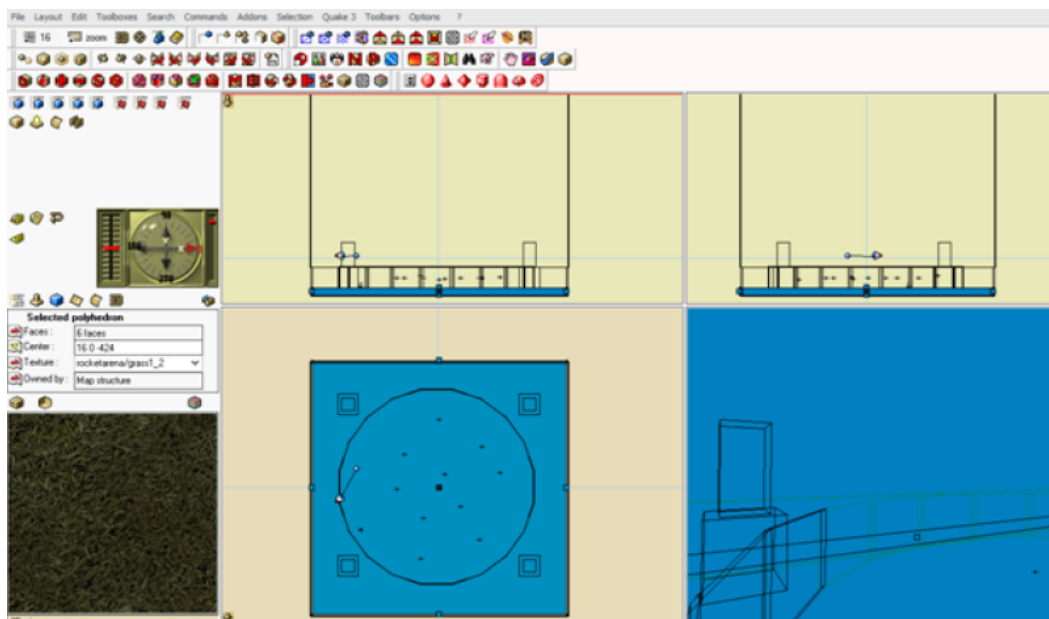


Figura 3.6: Interface da ferramenta de modelação gráfica 3-D *QuArK*®, no desenvolvimento de um cenário em forma de arena

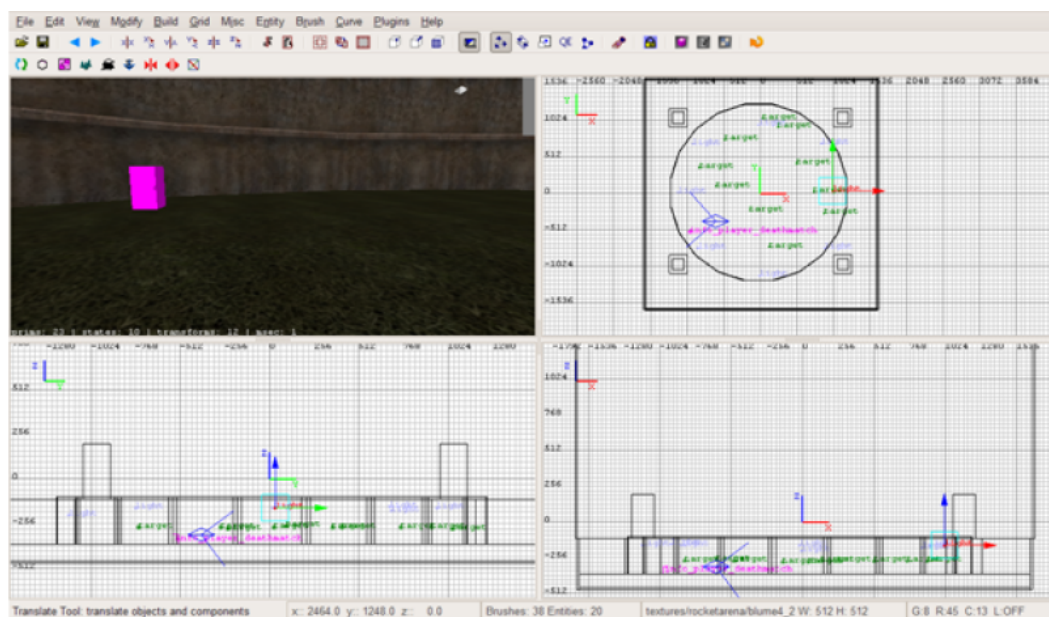


Figura 3.7: Interface *freeware* mais usada para modelação 3-D: *GTKRadiant*®

inúmeros fenómenos de interesse, que serão discutidos, mas pode ainda ser complementada por uma análise no domínio da frequência.

As características mais discriminativas de certos sinais EEG têm sido reportadas a determinadas regiões corticais em certas bandas de frequência. Tirando partido deste conhecimento *a priori*, é possível reduzir a dimensionalidade dos dados sem perda de informação relevante – este passo é designado por extracção de características. Estas características discriminativas podem ser obtidas, por exemplo, calculando bandas de potência em gamas de frequências e em localizações do escalpe bem definidas. Os métodos de filtragem espacial com recurso a montagens laplacianas mostraram

uma forma elegante, com poucos eléctrodos, de conseguir bons resultados[85][4][86]. No entanto, tais soluções são, por norma, independentes do sujeito: os eléctrodos seguem uma localização padrão e os filtros dimensionados têm margens bem definidas. Ao mesmo tempo, estas soluções não dão resposta ao problema da variabilidade dos dados que resulta da natureza não-estacionária e não-gaussiana dos sinais de EEG, tornando difícil a extracção de características estáveis e apropriadas à classificação (*i.e.*, separação dos dados no espaço das características).

Consequentemente, tem-se verificado um interesse crescente por métodos de aprendizagem automática que se adaptem a um cérebro específico. A intenção é usar técnicas avançadas de extracção de características sobre dados que tenham sido pré-processados usando à priori conhecimento neurofisiológico [87][88][8]. Neste contexto, esta secção descreve alguns métodos de extracção de características e classificação e apresenta a abordagem seguida neste trabalho.

3.2.1 Métodos de Aprendizagem

A operação fiável de BCIs baseadas em sinais electroencefalográficos espontâneos (EEG) requer uma classificação precisa dos dados EEG provenientes de múltiplos canais. O *design* de representações dos dados EEG, bem como classificadores viáveis em BCIs, são questões de investigação em aberto. A sua dificuldade reside na necessidade de extrair padrões espaciais e temporais complexos de dados com séries temporais multidimensionais muito ruidosas, provenientes das medições EEG.

Assim, a natureza multidimensional em sinais EEG, bem como a componente de ruído, podem limitar a vantagem que métodos de classificação não-lineares apresentam, em teoria, sobre os lineares. Nesta secção descrevem-se, de forma sumária, os algoritmos que provaram já a sua relativa utilidade na discriminação entre dados com duas (ou mais) classes.

Este trabalho de pesquisa é inevitavelmente incompleto, dada a quantidade de métodos, e refinamentos dos mesmos, continuamente em desenvolvimento. O seu conhecimento é importante, não só no processo de classificação propriamente dito, mas também na procura de formas de seleccionar aquelas características presentes nos dados que, estando intrinsecamente ligadas aos fenómenos a discriminar, maximizam a classificação. Na base da exposição sumária que se segue estão os trabalhos de (Hastie *et al.*) [89] – para os algoritmos de classificação – e (Whitley) [90] – para os algoritmos genéticos, que poderão ser consultados para detalhes adicionais.

3.2.1.1 Análise Linear Discriminante

Uma forma de classificar dados consiste em, primeiro, criar modelos de funções densidade de probabilidade para os dados gerados em cada classe. De seguida, as novas amostras são classificadas determinando a função densidade de probabilidade cujo valor é superior aos restantes. A Análise Linear Discriminante (LDA⁴) é um exemplo de tal algoritmo. A LDA assume que as funções densidade de probabilidade para cada classe podem ser modeladas como densidades normais (ou *gaussianas*), e que tais funções apresentam a mesma covariância para todas as classes.

Considere-se que existem K classes. Denote-se X_k como a matriz $p \times N_k$ (N_k amostras e colunas p -dimensionais, da classe de dados k). Definam-se também, previamente, as probabilidades π_k e médias μ_k de cada classe, assim como a matriz de covariância comum Σ ,

$$\pi_k = \frac{N_k}{\sum_{i=1}^K N_i} \quad (3.1)$$

⁴Do inglês, *Linear Discriminant Analysis*.

$$\mu_k = \frac{X_k 1 N_k}{N_k} \quad (3.2)$$

$$\sum = \frac{\sum_{i=1}^K (X_k - \mu_k 1^T N_k)(X_k - \mu_k 1^T N_k)^T}{N - K} \quad (3.3)$$

onde 1_m é uma matriz $m \times 1$ de 1's. Assim, uma nova amostra x é classificada por

$$\arg \max_k x^T (\sum \mu_k)^{-1} - \frac{1}{2} \mu_k^T (\sum \mu_k)^{-1}. \quad (3.4)$$

Os limites de decisão entre classes de dados são lineares.

3.2.1.2 Redes Neurais

Redes neurais artificiais são frequentemente utilizadas para desenvolver limites de classificação não-lineares. Entre as razões que levam à sua utilização estão: (1) a sua facilidade de aplicação, (2) a sua robustez à escolha do valor de parâmetros e (3) a sua similaridade a outros métodos de regressão não-lineares. O esquema conceptual de uma rede neuronal simples pode ser visto na Figura 3.8.




Figura 3.8: Representação simplificada de uma rede neuronal artificial “feedforward” (Fonte : Wikipedia)

De novo, considerem-se K classes. Seja X uma matriz $p \times N$ de N amostras e colunas p -dimensionais. Considere-se Y a matriz $K \times N$, contendo variáveis indicadoras da classe a que pertence cada amostra de X . Adicionalmente, α é a matriz $p + 1 \times h$ de pesos da camada oculta (*hidden layer*), onde h é o número de nós, e β a matriz $h + 1 \times K$ de pesos na camada de saída. A camada oculta de saída Z e a rede final de saída O são calculadas como

$$Z = f(\alpha^T X) \quad (3.5)$$

$$O = f(\beta^T Z) \quad (3.6)$$

onde $f(a) = \frac{1}{1 + e^{-a}}$.

O algoritmo de aprendizagem, baseado na propagação do erro (*backpropagation*⁵), é simplesmente um procedimento iterativo de gradiente descendente⁶ que minimiza o erro quadrático $(Y - O)^2$ somado

⁵É um método comum, por conseguinte bem documentado, de ensinar redes neurais artificiais a realizar uma dada tarefa.

⁶Do inglês *gradient descent*, é um algoritmo de optimização linear que procura um mínimo local de uma função, dando passos proporcionais ao negativo do gradiente da função no presente ponto.

sobre todas as saídas e amostras. O gradiente descendente é realizado actualizando os pesos como

$$\delta = (Y - O) \cdot O \cdot (1 - O) \quad (3.7)$$

$$\Delta\alpha = \gamma X(\beta\delta \cdot Z \cdot (1 - Z))^T \quad (3.8)$$

$$\Delta\beta = \gamma Z\delta^T \quad (3.9)$$

onde γ é uma constante pequena e o operador \cdot denota a multiplicação componente-a-componente. Estas equações são actualizadas iterativamente até que o erro quadrático na rede de saída de um dado subconjunto de dados seja minimizado. Os pesos resultantes são utilizados para classificar novos dados tomando a saída com maior valor.

3.2.1.3 SVMs

As redes neuronais convencionais podem ser difíceis de construir devido à necessidade de seleccionar um número adequado de nós. A rede deve conter nós suficientes para conseguir aproximar a função em questão à precisão desejada. Contudo, se a rede contiver demasiadas destas unidades, poderá simplesmente “memorizar” os dados de treino, o que origina uma generalização muito pobre.

A motivação primordial das *Support Vector Machines* (SVMs) é lidar directamente com o objectivo de uma boa generalização por, em simultâneo, maximizar a performance da máquina enquanto minimiza a complexidade do modelo aprendido. O problema de optimização da SVM é

$$\min_{\beta, \beta_0} \frac{1}{2} \|\beta\|^2 + \gamma \sum_{i=1}^N \xi_i \quad (3.10)$$

relativo a $\xi_i \geq 0$, $y_i(h(x_i)^T \beta + \beta_0) \geq 1 - \xi_i$.

O problema é transformado num problema de programação quadrática convexa que é resolvido através de técnicas convencionais. O resultado é uma função discriminante $f(x) = h(x)^T \beta + \beta_0$ que, quando combinada com o valor optimizado para β , se torna

$$f(x) = \sum_{i=1}^N \alpha_i y_i K(x, x_i) + \beta_0 \quad (3.11)$$

onde $K(x, x_i)$ é a função *kernel*[17], que é a mesma que o produto interno de $h(x)$ e $h(x_i)$. Esta peculiaridade do *kernel* permite que $h(x)$ tenha muitas dimensões, uma vez que nem sempre necessita de ser calculada. O teorema[91] de Cover para separabilidade de padrões diz, essencialmente, que o método não-linear de promover dados a um espaço de características de dimensionalidade superior tem mais possibilidades de conseguir uma separação linear do que aquele que recorre à dimensionalidade original, ou inferior. Ainda que a SVM produza uma função de decisão linear, a mesma é agora linear no espaço de características, e não no espaço de entrada. Devido à elevada dimensionalidade do espaço de características, pode esperar-se uma boa performance da função de decisão linear, de acordo com o teorema de Cover. Visto de outra forma, em virtude do mapeamento não-linear do espaço de características, a SVM é capaz de produzir funções arbitrárias de decisão no espaço de entrada, dependendo da função *kernel*. O teorema de Mercer[92] fornece a base teórica para determinar em que condições uma dada função *kernel* K é igual a um produto interno em algum espaço, requisito para admissibilidade como *kernel* SVM. Dois exemplos de tais funções são o *kernel* polinomial $K(x_i, x_j) = (x_i^T x_j + 1)^p$ e a função *kernel* de base radial (RBF), $K(x_i, x_j) = \exp(-(1/2\sigma^2)\|x_i - x_j\|^2)$. A melhor forma de aplicar SVMs ao caso multiclasse é um problema de investigação em curso. O método DAGSVM, proposto por Platt *et al.*[12], baseia-se na noção de grafos de decisão direccionados acíclicos

(DDAGs). Um dado DDAG é avaliado de forma muito semelhante a uma árvore de decisão binária, onde cada nó interno implementa a decisão entre duas das k classes do problema de classificação. No algoritmo DAGSVM, cada nó de decisão usa uma SVM $1 - v - 1$ para determinar que classe eliminar de consideração. Um classificador adicional deve ser construído para separar todos os pares de classes.

3.2.1.4 Extracção de Características com Algoritmos Genéticos

A análise a aspectos espaciais, temporais ou espectrais de dados de elevada resolução, permitindo interacções entre ambos, leva a espaços de características de elevada dimensionalidade. Contabilizar uma alta percentagem de potenciais características, nos dados medidos, requer capacidades de análise e classificação superiores. A selecção de uma gama de características que sejam mais úteis ao problema da classificação frequentemente causa um aumento na taxa de classificação dos dados. Uma abordagem à selecção de características que não faz qualquer “suposição” sobre a relação entre as mesmas envolve a utilização de algoritmos genéticos (GA) para a procura em certas gamas do espaço de características[15][14].

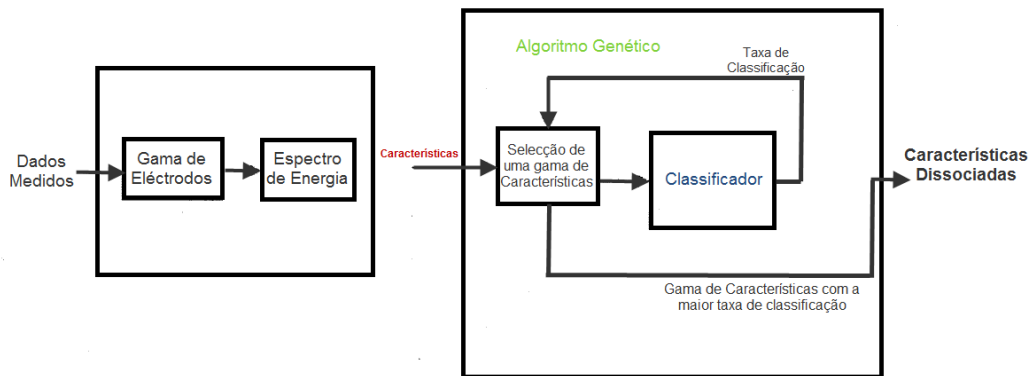


Figura 3.9: Arquitectura do sistema para sub-divisão do espaço de características dos sinais EEG. A divisão é feita num estilo “wrapper”, pelo que é direccionada à *performance* do classificador (que poderá ser, por exemplo, uma SVM)

A utilização de algoritmos genéticos é útil na extracção de características por dois motivos. Primeiro, a exploração exhaustiva de espaços que contenham, tipicamente, mais de 20 características é computacionalmente intratável (i.e., 2^{20} possíveis combinações). Em segundo lugar, ao contrário de métodos de procura baseados em gradiente (já expostos), o GA está inerentemente desenhado para evitar a convergência em valores óptimos que apenas sejam locais.

3.2.1.5 Considerações Finais

Algoritmos baseados em SVM fornecem um método poderoso para classificação de dados. Possuem “fundações” bastante sólidas em teoria de aprendizagem estatística, e garantem a obtenção da função de decisão óptima para um conjunto de dados de treino, dado uma série de parâmetros que determinam a sua operação. Diversos estudos [93][9] comprovam, contudo, que algoritmos de discriminação lineares ou baseados em redes neuronais têm uma *performance* apenas marginalmente inferior.

De notar que as transformações de sinal tratadas nesta secção contemplam espectros de energia ou ainda coeficientes de auto-regressão. Existem outras transformações que mostram resultados

promissores no isolamento de componentes-chave de um sinal. A análise independente de componentes (ICA), frequentemente utilizada para a remoção de componentes artefactuais[11], pode originar representações que aumentam a classificação. Quando a quantidade de dados disponíveis para treino é limitada e, ainda, quando o conhecimento sobre a distribuição dos mesmos não é bem conhecida, recomendam-se métodos lineares de classificação. Esta afirmação é particularmente verdadeira quando as medições contêm grande quantidade de artefactos. Ainda assim, as características mais importantes devem ser extraídas recorrendo a métodos que permitam antever comportamentos não-lineares de interesse à discriminação.

Entre os métodos até aqui apresentados, não foi ainda referido um aspecto fundamental que os distingue. Para o conjunto de sujeitos de teste, haverá aqueles que apresentam padrões – tempo-frequência – ERD/ERS (visivelmente) mais discriminantes. A extracção de características (i.e., melhor localização dos eléctrodos e bandas de frequência óptimas), pode estar baseada no conhecimento *a priori* dos níveis ERD/ERS. Desta maneira, a selecção feita usando propriedades que se ajustam à teoria é um método valioso para a classificação. Importa, portanto, perceber e validar a influência que têm, na classificação, diversos métodos de selecção de características. Não apenas daqueles que partem de um conhecimento *a priori* mais “restrito”; outros métodos foram descritos, genericamente designados *Blind Source Separation* (ou BSS), que actuam sobre um conjunto (numérico) de dados, sem conhecimento prévio do seu “significado” ou nível de importância, procurando obter uma nova representação, muitas vezes de dimensionalidade reduzida, mais favorável à discriminação.

O exemplo mais famoso de redução de dimensões é conhecido por *Principal Component Analysis* (PCA). Esta técnica procura as direcções, entre os dados, que apresentam maior variância e projecta os mesmos sobre elas, aplicando uma mudança de escala. Desta forma, obtém-se uma representação de menor dimensão, removendo aquela(s) que aparenta(m) ser mais ruidosa(s). Enquanto técnica não-supervisionada, não recorre à informação sobre a classe (*label*) dos dados. Atente-se no exemplo da Fig.3.10.




Figura 3.10: *Principal Component Analysis* e *Linear Discriminant Analysis* : duas estratégias, com propósitos distintos, para redução da dimensionalidade dos dados

Representam-se a vermelho e verde amostras pertencentes a duas classes distintas. Estes dois conjuntos de dados estão posicionados quase em paralelo e muito próximos um do outro, pelo que a variância no conjunto total de amostras (ignorando os *labels*), está na direcção representada a preto. Para a classificação, esta seria uma projecção terrível, já que os *labels* ficariam misturados de forma bastante “emparelhada”. Uma outra projecção, muito mais útil, será a ortogonal (representada a azul), i.e., aquela que está na direcção da menor variância das amostras.

Portanto, a questão é: como utilizar a informação dos *labels* na procura de projecções informativas? Para esse propósito, a análise linear discriminante de Fisher será considerada na Secção 3.2.2.2.

3.2.2 Metodologia Adoptada

O objectivo do trabalho é proceder ao estudo e validação de formas mais abrangentes de seleccionar, para cada indivíduo, um subconjunto personalizado de propriedades presentes nos dados que maximizem a discriminação de vários estados mentais. Em relação a todos eles, em particular aqueles que dizem respeito à imaginação motora, serão identificadas as propriedades que favorecem a discriminação, nomeadamente os níveis de ERD/ERS dos ritmos *mu*. A metodologia adoptada neste trabalho parte do princípio que, para além de se poderem obter melhores taxas de decisões correctas, os algoritmos a implementar devem contribuir para uma melhor interpretação do paradigma de operação usado. Por outras palavras, pretende-se encontrar as características mais relevantes para classificação e, em simultâneo, estabelecer uma comparação com o conhecimento neurofisiológico existente.

3.2.2.1 Extracção de Características Relevantes para Classificação

Para extracção de características, apresenta-se uma extensão do classificador *Learning Vector Quantization* (LVQ)[19], conhecida como *Distinction Sensitive Learning Vector Quantization* (DSLQV)[94][16]. O DSLQV usa uma função distância pesada, em lugar da tradicional distância *Euclidean*. A influência das diferentes características de entrada é ajustada com valores de pesos, treinados para aproximar a relevância das características correspondentes. Este processo dinâmico de ajuste visa libertar o sistema, tanto quanto possível, da importância dos métodos de pré-processamento para selecção de características, que é uma limitação importante do LVQ *standard*. Mostrou-se já que é um poderoso classificador de sinais EEG multidimensionais[13]. O seu nível de reconhecimento supera os sistemas LVQ, e os pesos resultantes do processo fornecem resultados muito razoáveis. A sua principal vantagem é a simplicidade: o sistema não requer experiência ou métodos explícitos para normalização ou selecção de características. Além disso, é possível rever a extracção de características com amostras adicionais, de teste. Esta consideração é particularmente importante para aplicações onde a relevância de certas características possa variar durante a operação do sistema. Uma BCI é um exemplo de tal aplicação: o cérebro humano é sujeito a um processo permanente de aprendizagem e, como tal, a extracção de características na BCI necessita uma adaptação contínua.

A ideia do LVQ é a de aproximar limites de decisão óptimos entre diferentes classes num espaço de características N -dimensional, usando um certo número de vectores de referência catalogados (*codebook vectors*). Como exemplo, um vector \mathbf{x} é classificado de acordo com o seu *codebook* mais próximo, de acordo com uma função distância, por norma, *Euclidean*. Cada *codebook* é inicializado, por exemplo, com recurso a um método do tipo *k-means clustering*, e depois afinado iterativamente com um dos algoritmos de treino LVQ[19][95]. Uma breve descrição do mais avançado, o LVQ3, é introduzida.

O primeiro passo numa iteração de treino t do LVQ3 é a determinação dos dois *codebooks* mais próximos à presente amostra de teste $\mathbf{x}(t)$, que serão referidos como \mathbf{m}_i e \mathbf{m}_j . Seguidamente, uma “janela” simétrica (de largura não nula) em torno de \mathbf{m}_i e \mathbf{m}_j deve ser especificada. Um vector \mathbf{x} é

definido como pertencendo à “janela” se

$$\min\left(\frac{d_i}{d_j}, \frac{d_j}{d_i}\right) > s \quad (3.12)$$

onde s representa um factor constante, escolhido vulgarmente entre 0.4 e 0.8, e d_i e d_j são as distâncias de \mathbf{x} a \mathbf{m}_i e \mathbf{m}_j , respectivamente. O processo de treino do LVQ3 atualiza depois \mathbf{m}_i e \mathbf{m}_j de acordo com as seguintes equações:

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) - \alpha(t)[\mathbf{x}_t - \mathbf{m}_i(t)] \quad (3.13)$$

$$\mathbf{m}_j(t+1) = \mathbf{m}_j(t) - \alpha(t)[\mathbf{x}_t - \mathbf{m}_j(t)] \quad (3.14)$$

se \mathbf{x} pertence à “janela” e \mathbf{x} e \mathbf{m}_j pertencem à mesma classe, enquanto \mathbf{x} e \mathbf{m}_i pertencem a classes diferentes; ou

$$\mathbf{m}_k(t+1) = \mathbf{m}_k(t) + \epsilon\alpha(t)[\mathbf{x}_t - \mathbf{m}_k(t)], k \in i, j \quad (3.15)$$

se \mathbf{x} pertence à “janela” e \mathbf{x} , \mathbf{m}_j e \mathbf{m}_i pertencem à mesma classe. Aqui, $\alpha(t)$ é um ganho escalar, que decresce monotonamente no tempo. Um valor inicial comum é $\alpha(0) = 0.03$. ϵ é uma constante, e os valores aplicáveis estão entre 0.1 e 0.5[19].

Por sua vez, o DSLVQ é inicializado com um vector de igual peso para todas as características, $\mathbf{w} = (w_1, w_2, \dots, w_N)$. Depois de um breve período de treino inicial, um processo de aprendizagem adicional começa a adaptar iterativamente o valor dos pesos; conceptualmente, divide o problema em sub-problemas considerando apenas uma característica de cada vez, e procura sub-problemas fáceis, ou seja, aqueles com baixas taxas de erro. Actualiza assim os pesos associados à relevância das características, de acordo com estas heurísticas. Contudo, alterações nos pesos podem levar a que a posição dos *codebooks* deixe de ser óptima, pelo que treino adicional sobre os mesmos será necessário. Assim, o DSLVQ continua a aprendizagem dos *codebooks* durante a aprendizagem iterativa das relevâncias (pesos). Em termos de estabilidade, nenhuma experiência deu evidências de que existam distúrbios durante a aprendizagem, em simultâneo, destes dois aspectos (*codebooks* e pesos). Comparado com estruturas comuns de redes neuronais (NN), como perceptrões multicamada, é uma grande vantagem do DSLVQ o facto de a pesagem de características ser transparente; a transparência é particularmente importante na inicialização do sistema e na explicação dos seus resultados.

Na essência, o vector de pesos \mathbf{w} é usado pelo classificador DSLVQ para variar a influência de diferentes características na classificação. Como a classificação em sistemas LVQ está baseada em distâncias num espaço de características N -dimensional, os valores podem simplesmente ser usados como factores de multiplicação nas sub-distâncias das correspondentes características; este processo pode ser visto como uma transformação de escala do espaço original para um espaço DS de características: aumenta distâncias entre os valores das características mais discriminantes e diminui distâncias nas dimensões menos informativas, o que torna o sistema menos sensível a ruído. A função distância empregue será então

$$DS_{DIST}(\mathbf{w}, \mathbf{x}, \mathbf{y}) = \sqrt{\sum_{n=1}^N [\max(0, w_n)(x_n - y_n)]^2} \quad (3.16)$$

A abordagem aqui feita foi a de uma distância *Euclideana*, mas pesada, embora nada impeça outras alternativas. Os valores negativos para o peso podem ser permitidos no processo de aprendizagem da relevância apenas para simplificar uma aproximação iterativa dos pesos. Contudo, uma vez que o processo se baseia na aprendizagem de exemplos positivos para a associação a uma classe, os valores

usados para classificação devem também ser positivos (ou simplesmente nulos, quando o DSLVQ não consegue observar nenhuma característica discriminatória de classes nos exemplos de treino).

Apesar da utilização de outra função distância, a aprendizagem dos *codebooks* para o DSLVQ é a mesma que para o LVQ3. De facto, se os pesos forem inicializados de forma equitativa, a primeira iteração no treino de ambos será em tudo idêntica.

A aprendizagem da relevância/pesos deve ser atrasada até que a posição dos *codebooks* esteja aproximadamente fixa; pesos e vectores de referência são depois actualizados em paralelo a cada iteração de aprendizagem. Pode assumir-se que, para uma dada iteração t , \mathbf{m}_i e \mathbf{m}_j são os dois *codebooks* mais próximos à amostra de treino $\mathbf{x}(t)$, que \mathbf{m}_j e \mathbf{m}_i pertencem à mesma e a classes diferentes de \mathbf{x} , respectivamente, e que \mathbf{x} pertence à “janela” (condições para aprendizagem do LVQ3). Pode então descrever-se o processo de aprendizagem de pesos com a seguinte equação:

$$\mathbf{w}(t+1) = \text{norm}(\mathbf{w}(t) + \alpha(t)[\mathbf{n}\mathbf{w}(t) - \mathbf{w}(t)]) \quad (3.17)$$

com

$$\mathbf{n}\mathbf{w}(t) = \text{norm}\left(\frac{d_{i_n}(t) - d_{j_n}(t)}{\max(d_{i_n}(t), d_{j_n}(t))}\right) \quad (3.18)$$

$$\text{norm}(\mathbf{y}) = \frac{1}{\sum_{n=1}^N |y_n|} \mathbf{y} \quad (3.19)$$

$$d_{k_n}(t) = |x_n(t) - m_{k_n}(t)|, k \in i, j \quad (3.20)$$

A função de normalização $\text{norm}(\mathbf{y})$ é uma transformação de escala para o vector

$$\mathbf{y} = (y_1, y_2, \dots, y_n).$$

O resultado será um vector de pesos cuja soma é 1. Uma vez que os vectores \mathbf{w} e $\mathbf{n}\mathbf{w}$ são normalizados desta maneira, o processo pode ser encarado como a redistribuição de um número limitado de créditos, tendencialmente para as características de entrada mais relevantes.

Comprova-se, por fim, que a principal vantagem do algoritmo DSLVQ é que não requer experiência, conhecimento *a priori* ou suposição acerca da distribuição dos dados. Mais, não só se identificam as características relevantes, como ainda a combinação entre as mesmas[13].

3.2.2.2 Classificador Baseado na Análise Discriminante de Fisher

Embora os termos *Discriminante Linear de Fisher* e *LDA* (apresentada na Secção 3.2.1.1) sejam frequentemente usados no mesmo contexto, o artigo [96] original de Fisher descreve, na verdade, uma discriminação ligeiramente diferente, onde não são tidas em conta algumas das suposições que estão na base da LDA, como a distribuição normal das classes e igual covariância.

Suponha-se que duas classes de observações têm médias $\mu_{y=0}$, $\mu_{y=1}$ e covariâncias $\Sigma_{y=0}$, $\Sigma_{y=1}$. Então, a combinação linear das características $\mathbf{w} \cdot \mathbf{x}$ terá médias $\mathbf{w} \cdot \mu_{y=i}$ e variâncias $\mathbf{w}^T \Sigma_{y=i} \mathbf{w}$, para $i = 0, 1$. Fisher definiu a separação entre estas duas distribuições como a razão da variância **entre** classes e a variância **dentro** das classes:

$$S = \frac{\sigma_{between}^2}{\sigma_{within}^2} = \frac{(\mathbf{w} \cdot \mu_{y=1} - \mathbf{w} \cdot \mu_{y=0})^2}{\mathbf{w}^T \Sigma_{y=1} \mathbf{w} + \mathbf{w}^T \Sigma_{y=0} \mathbf{w}} = \frac{(\mathbf{w} \cdot (\mu_{y=1} - \mu_{y=0}))^2}{\mathbf{w}^T (\Sigma_{y=1} + \Sigma_{y=0}) \mathbf{w}} \quad (3.21)$$

Esta medida é, em certo sentido, uma analogia à relação sinal-ruído aplicada à classe das amostras. Pode demonstrar-se que a separação é máxima para

$$w = (\Sigma_{y=1} + \Sigma_{y=0})^{-1}(\mu_{y=1} - \mu_{y=0}) \quad (3.22)$$

Quando os pré-requisitos da LDA são satisfeitos, a Eq. 3.22 torna-se equivalente à LDA. Note-se que o vector w é normal ao hiperplano discriminante. Como no exemplo anterior (Fig. 3.10), a duas dimensões, a linha que melhor divide os dois grupos é perpendicular a w .

O método é então o seguinte: os pontos a discriminar são projectados sobre w , e o *threshold* que melhor separa os dados é escolhido para análise da distribuição 1-dimensional. Não há uma regra geral para o *threshold*; contudo, se as projecções dos pontos em ambas classes exibirem aproximadamente a mesma distribuição, a boa escolha seria o hiperplano mediador da projecção das duas médias, $w \cdot \mu_{y=0}$ e $w \cdot \mu_{y=1}$. Nesse caso, o parâmetro c na condição de *threshold* $w \cdot x < c$ pode ser encontrado explicitamente:

$$c = w \cdot \frac{\mu_{y=0} + \mu_{y=1}}{2} \quad (3.23)$$

Para a tarefa de classificar estados mentais foram implementados, em primeiro lugar, dois classificadores: na presença de dois estados mentais, um LDA de Fisher, aplicado a um sub-conjunto de características seleccionadas como mais relevantes, é usado. No caso de três classes, implementou-se uma combinação de três LDAs, cada um associado a um par de classes; nestas circunstâncias, o resultado da classificação, para cada amostra, será o voto da maioria. Na decisão de cada um dos LDAs, apenas o respectivo cálculo do threshold é tomado como referência para uma decisão.

3.2.3 Dados de Treino e Teste

Os algoritmos de aprendizagem adoptados requerem exemplos que permitam a detecção de sinais cerebrais relevantes. Mais ainda, os dados escolhidos deverão ser divididos entre os relativos à fase de treino e aqueles usados em fase de teste. Para o efeito, são seleccionados um conjunto de dado de EEG associados a vários utilizadores que, repetidamente, produzem certos estados mentais, com incidência para a imaginação motora:

Martigny

- Um conjunto de três sujeitos de teste, cada um com 4 sessões (realizadas no mesmo dia) de 4 minutos, e intervalos de 15 minutos. A última sessão destina-se ao teste do classificador;
- Três Estados, dois deles para imaginação motora : (1) mão esquerda, (2) mão direita e (3) imaginação repetida de palavras começadas pela mesma letra;
- Estímulos com elevada duração (cerca de 15 a 20 segundos cada);
- Dados amostrados a 512Hz, e posteriormente sub-amostrados para 256Hz, num total de 32 canais;
- Origem : *IDIAP Research Institute* (José del R. Millán);
- *BCI Competition III - Dataset V*.

Berlim

- Cinco sujeitos de teste, em sessões únicas de longa duração;
- 280 *trials* para dois estados de imaginação motora : (1) Mão direita e (2) Pé;
- *Trials* de curta duração (3.5 segundos), separados por intervalos de relaxamento variáveis;
- Dados amostrados a $1000Hz$, e posteriormente sub-amostrados para $250Hz$, num total de 118 canais.
- Pela especificidade dos momentos de relaxamento, os dados contêm uma quantidade considerável de artefactos oculares e musculares.
- Uma percentagem considerável dos dados foi recolhida em sessões (sem *feedback*) onde o estímulo foi apresentado através de uma *interface* gráfica com setas em movimento, que podem induzir artefactos oculares. Trata-se de uma analogia de interesse no estudo da viabilidade de testes sem *feedback* em ambientes gráficos/virtuais.
- Origem : *Fraunhofer FIRST, Intelligent Data Analysis Group* (Klaus-Robert Müller, Benjamin Blankertz), e *Campus Benjamin Franklin of the Charité* - Universidade de Medicina de Berlim, Dep. de Neurologia, Grupo de Neurofísica (Gabriel Curio);
- *BCI Competition III - Dataset IVa*.

3.2.4 Ambiente de Desenvolvimento

Ao longo do trabalho foram usadas várias ferramentas software que, pelas suas características próprias, se mostraram importantes no desenvolvimento, implementação e teste dos algoritmos propostos. De seguida, faz-se uma descrição breve das características e funcionalidades do *Matlab*, *Simulink* e *EEGLab*.

3.2.4.1 *Matlab*

Matlab é um ambiente para programação de alta *performance*, usado em aplicações numéricas e técnicas. A primeira versão foi escrita na Universidade do Novo México nos anos 1970s. Também conhecido como “MATrix LABoratory”, foi inventado por Clive Moler para permitir uma forma simples e interactiva de escrever programas usando as bibliotecas *Linpack* e *Eispack*, presentes em sub-rotinas da linguagem FORTRAN, que lidam com manipulação de matrizes. Desde então, evoluiu até se tornar uma eficaz e poderosa ferramenta para programação, visualização e análise de dados, educação, engenharia e pesquisa em geral.

Os seus pontos fortes são a forma extensiva como permite lidar com vários tipos de dados, a existência de poderosas ferramentas de programação, as suas habilidades gráficas e a inclusão de uma gama muito alargada de algoritmos complexos. Trata-se de um ambiente especializado em computação numérica, como é também capaz de fazer computação simbólica, partilhando uma interface com o *Maple*®, ambiente líder nesse domínio. Além da rápida computação numérica para álgebra linear e da disponibilidade de uma grande quantidade de métodos específicos aos mais variados domínios (e.g., estatística, optimização, processamento de imagem, redes neuronais), outra funcionalidade útil do *Matlab*® é a sua capacidade de facilmente gerar várias perspectivas de visualização para os mesmos dados e/ou resultados de simulação. Para cada aspecto do *Matlab*® em geral, e para os gráficos em

particular, a utilidade desta ferramenta assenta na gama alargada de funções e bibliotecas *built-in*. O sistema de ajuda *online* revelou-se indispensável nesse sentido.

Em síntese, combina computação, visualização e programação em torno do conceito central de matriz, e quase tudo é representado nesse ambiente em termos de matrizes ou operações sobre as mesmas. Usado devidamente, o *Matlab*® provou ser de infinita utilidade na expressão e resolução de variados problemas, emergentes no contexto de estudo.

3.2.4.2 *Simulink*

Trata-se de um ambiente para simulações nos mais variados domínios, permitindo a criação de sistemas dinâmicos através de um *design* baseado em modelos. Proporciona um ambiente gráfico e um conjunto personalizável de bibliotecas de blocos que permitem projectar, simular, implementar e testar uma variedade de sistemas, incluindo comunicações, controlo, ou ainda processamento de sinal, vídeo e imagem. Muito sucintamente, podemos considerar alguns pontos de relevância, que são fortes complementos ao ambiente *Matlab*:

- Permite observar o comportamento dos sistemas de uma forma prática e fácil;
- Permite representar os sistemas de controlo como se de um diagrama de blocos se tratasse;
- Aplicável para sistemas de controlo discretos;
- Cooperação entre os ambientes *Matlab* e *Simulink*: é permitido exportar e importar informação entre ambos;
- Existência de um conjunto de blocos pré-definidos, que incluem controladores, filtros, elementos somadores ou funções de transferência, entre muitos outros;
- Capacidade de utilização de bibliotecas de tempo real para aplicações prioritárias.

3.2.4.3 *EEGLab*

EEGLAB é uma *toolbox* interactiva do *Matlab*, para processamento de dados contínuos, ou relativos a eventos, de sinais EEG, MEG ou outros dados electrofisiológicos, incorporando também análise independente de componentes (Independent Component Analysis, ICA), análises tempo/frequência, rejeição de artefactos, estatística relacionada com eventos e variados métodos de visualização úteis de dados médios ou *single-trial* (Figura 3.11). Desenvolvido inicialmente em *Matlab v5.3* para *Linux*, esta ferramenta é hoje compatível, e recomendada, com versões recentes do *Matlab*, correndo em sistemas operativos *Linux*, *Unix*, *Windows* e *Mac OS X*.

Nos tópicos seguintes sumariam-se as principais capacidades desta *toolbox*:

- Interface gráfica (GUI);
- Importação de dados em múltiplos formatos;
- Visualização (*scrolling*) de dados de elevada densidade;
- Estrutura de dados EEG definida;
- Acesso a *plug-ins* de código aberto.
- Funções de traçado gráfico interactivas;

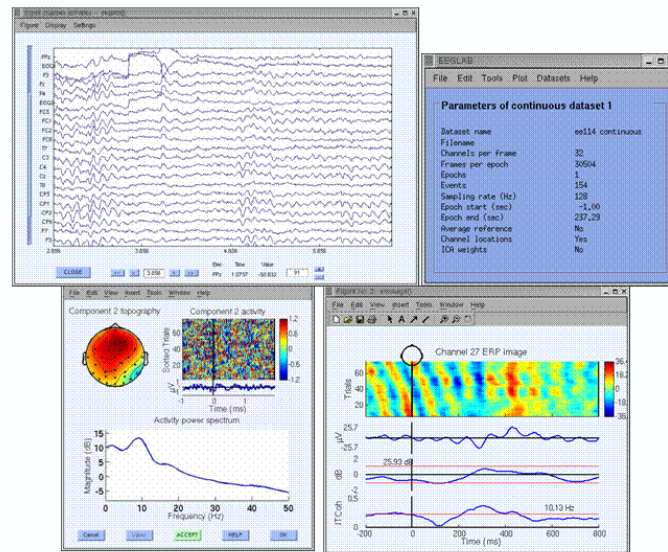


Figura 3.11: Aspecto visual da toolbox *EEGLAB*

- Remoção semi-automática de artefactos;
- ICA e Medições tempo/frequência;
- Permite manipulação de eventos ou canais.

Capítulo 4

Adaptação Baseada em Aprendizagem

“Controlling complexity is the essence of computer programming.”

– Brian Kernigan

Neste capítulo descrevem-se as questões de implementação dos algoritmos de aprendizagem automática já adoptados e faz-se uma análise dos resultados obtidos. Em primeiro lugar, descrevem-se os métodos usados na filtragem passa-banda e na estimação da densidade espectral de potência. Em segundo lugar, a análise efectuada é dividida em duas partes relativas aos dados de Martigny (Secção sec:MartignyResults) e de Berlim (Secção sec:ResultsBerlin). Em qualquer dos casos, o objectivo é a aplicação dos métodos de aprendizagem de forma que o processamento se adapte a um utilizador específico, tendo em vista a optimização dos processos de discriminação das tarefas mentais. Mais concretamente, pretende-se extrair um conjunto de características relevantes associadas à localização dos eléctrodos (derivações monopolares) ou pares de eléctrodos (derivações bipolares), às janelas temporais usadas e às frequências de interesse numa banda pré-definida. Enquanto técnica de filtragem espacial, a utilização de derivações bipolares, em alternativa a canais monopolares, pretendeu reflectir de forma localizada as variações de potencial eléctrico no escalpe.

4.1 Filtragem Passa-Banda e Espectro de Potência

Os dados originais são valores de potencial eléctrico, medidos em μV , depois filtrados com um passa-banda *Butterworth* de 10ª ordem (Figura 4.1), com frequências limite de 7 e 37 Hz. A literatura aponta que, na maioria dos sujeitos, um filtro de ordem 5 é suficiente [97][98]. Não tendo sido encontrada uma metodologia única para a escolha mais adequada, a eficácia do filtro foi validada observando a evolução do seu espectro, que se discute de seguida. A banda seleccionada é relevante no estudo da imaginação motora [99].

Fenómenos ERD nas bandas *alpha* ou *beta* inferior são característicos de áreas corticais prontas a processar informação ou preparar um movimento, enquanto fenómenos ERS nas mesmas bandas podem ser vistos como correlações electrofisiológicas de áreas corticais em repouso[99]. A sua detecção será baseada no cálculo da densidade espectral de potência que, enquanto quantidade numérica, fornece ao processo de aprendizagem evidências do fenómeno em causa.

O carácter não-estacionário dos sinais EEG coloca o desafio de estimar, com relativa precisão, a energia contida nas bandas de frequência a estudar, usando para o efeito janelas de tempo com curta




Figura 4.1: Resposta em frequência do filtro passa-banda utilizado

duração. Se o sinal for relativamente estacionário em pequenos intervalos de tempo, ou próximo disso, a transformada de Fourier aplicada em sucessivas janelas temporais poderá fornecer bons resultados. Contudo, esta abordagem “quebra” nos limites do intervalo considerado, por violar a suposição de sinal estacionário que tal transformação assume. Uma forma de ultrapassar este problema consiste em utilizar janelas de tempo sobrepostas, e é conhecida como *short-time Fourier Transform* (ou STFT). Existem outras formas de caracterizar essas janelas, i.e, encontrar funções do tipo $w(t)$ capazes de minimizar o efeito dos artefactos nas margens do segmento: (1) a janela de *Hamming*, (2) a janela de *Hann*, ou ainda (3) a combinação da STFT com uma função janela do tipo *gaussiano*, também conhecida como método de Gabor, são alguns exemplos. Em suma, escolher segmentos temporais pequenos permite localizar melhor pequenas flutuações numa dada frequência, mas considera menos pontos e por isso consegue uma resolução menor (especialmente a baixas frequências), pelo que existe um compromisso tempo-frequência.

Numa primeira etapa, os dados a testar terão sido convenientemente transformados numa representação a três dimensões: Segmentos de Tempo \times Canais de Entrada \times Número de Frequências. À primeira dimensão vem associado um vector que caracteriza, no presente contexto, a classe relativa a esse “instante” (p.e., o tipo de imaginação motora realizada). Se o processo de transformação das amostras e escolha do tamanho de cada dimensão forem adequados, é possível encontrar métodos, descritos genericamente na Secção 3.2.1, capazes de discriminar entre duas ou mais classes, e de utilização recorrente na área de BCIs.

Para efeitos de extracção de características, foi utilizada uma escala logarítmica da estimativa das DEPs. Esta transformação numérica privilegia as pequenas flutuações presentes nos sinais de interesse, e não tanto as grandes, normalmente associadas a outras funções biológicas, artefactos ou estímulos de origem externa. Então, as amostras correspondem ao logaritmo de alguns valores da densidade espectral de potência (DEP), estimados tomando valores de amplitude contidos numa dada fracção de tempo, por cada derivação bipolar.

A DEP foi calculada, em cada canal¹, 8 vezes por segundo; de cada uma dessas estimativas, resulta um vector que contém valores de DEP para frequências que vão desde a componente DC até metade da frequência de amostragem (teorema de amostragem de Nyquist–Shannon). Concretamente, deste vector são apenas considerados os valores cujas frequências que vão desde 8 até 34 Hz, com um espaçamento/resolução de 2 Hz, o que resulta em 14 amostras. Tal gama será suficiente para abranger frequências associadas às bandas *alpha* e *beta*, em particular da variação na percentagem de ERD/ERS manifestados pelos ritmos *mu*, contidos na primeira. Ao mesmo tempo, o cuidado na pré-selecção

¹Neste contexto, “canal” pode significar efectivamente um canal monopolar, mas também uma derivação bipolar ou, ainda, uma componente independente resultante da decomposição ICA aplicada aos canais monopolares.




Figura 4.2: Densidade Espectral de Potência (para 7 canais monopolares) de sinais EEG, sem filtragem, obtidos durante uma sessão. Pode observar-se que a distribuição espacial de energia na banda *alpha* varia bastante (de facto, é mais proeminente na região parietal). A influência da frequência da rede eléctrica (50Hz) é também evidente

de um número “limitado” de amostras é uma questão de eficiência computacional mas, igualmente, de estabilidade nos processos de aprendizagem e classificação[8]. Por outro lado, ao seleccionar frequências com resolução de 2Hz , o atraso temporal (*blur*) e a resolução espectral são aceitáveis.

De um ponto de vista mais técnico, a estimativa das DEPs – para efeitos de aprendizagem – recorre a janelas de 1 segundo. Para conseguir as 8 estimativas por segundo estipuladas, foi necessária uma sobreposição de janelas (*overlap*), adequada à frequência de amostragem dos dados. Para a obtenção das estimativas de DEP com resolução 2Hz , o tamanho da janela FFT adequado será igual a metade da taxa de amostragem. Em relação à escolha do tamanho da janela de tempo, foi possível comprovar como janelas menores degradam as estimativas da DEP – por conterem menos amostras – o que, em última análise, terá algum impacto na classificação. Apesar de a plataforma de *software* desenvolvida permitir a configuração de todos os parâmetros referidos, considerou-se que um estudo comparativo e formal a esse nível seria demasiado exaustivo para aqui ser contemplado.

O último aspecto relativo ao tratamento das amostras diz respeito ao método de estimação das DEPs. O *Simulink* contém diversos módulos para o efeito, que não serão detalhados. Foram estudadas três possibilidades – Método de Yule-Walker, Método de Burg e Método de Welch (ou Periodograma) – ilustrados nas Figuras 4.3 e 4.4.

É observável, em primeiro lugar, a eficácia da filtragem passa banda realizada, e esse é um aspecto bastante coerente nos três métodos. Em particular, a forte atenuação nas baixas frequências (próximas da componente DC) é desejável porque não são conhecidos padrões ERD/ERS a elas associados. Também nas baixas frequências está contida a maior parte da energia presente em sinais EEG, e a sua presença pode degradar a relação sinal/ruído na banda de interesse. Os três métodos disponíveis são testados usando ordens de estimação iguais, e esse é um parâmetro configurável no *software*, tal como o tamanho da janela FFT.

Na Figura 4.2 está apresentado o espectro típico de sinais EEG. A partir da banda *alpha*, a energia contida em frequências superiores diminui gradualmente. Neste contexto, o método de Welch parece apresentar alguma instabilidade². Por outro lado, os métodos de Yule-Walker e Burg estão bastante correlacionados, o que pode indiciar a correcta representação do espectro. O primeiro foi preferido por conduzir a classificações com resultados marginalmente superiores. Alternativas aos casos destacados

²Esta evidência acentua-se aumentando o tamanho/resolução da janela FFT (por exemplo, *FFT Length* = 1024).

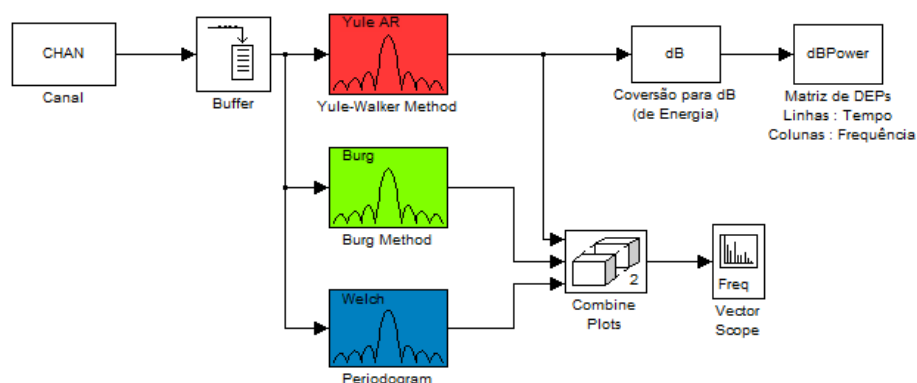


Figura 4.3: Plataforma Simulink para estudos comparativos de diversos métodos de estimativa de DEPs




Figura 4.4: A plataforma permite um acompanhamento dinâmico da evolução do espectro com o tempo amostral; apresenta-se um exemplo da distribuição do espectro de energia, estimado pelos três métodos contemplados, ambos de ordem 20, e com uma janela FFT de 128 valores para um *buffer* com 256 amostras, correspondentes – no *dataset* de Martigny – a um segundo de aquisição

– como são as *Wavelets* – não foram contempladas, mas serão merecedoras de um estudo futuro mais detalhado.

4.2 Análise dos dados de Martigny

Enquanto primeira análise, serão usados os dados de Martigny (três sujeitos de teste, três estados mentais) para avaliação do desempenho na classificação. Aqui serão compreendidas as dificuldades em reconhecer padrões quando as janelas de tempo dedicadas à imaginação de cada estado são grandes. Mais, poderá verificar-se como existem “ranhuras” de tempo, após estímulo, nas quais a detecção desses padrões é mais eficaz. Uma dificuldade acrescida, que será também comum ao estudo dos dados de Berlim, está relacionada com a variação do nível de energia dos sinais ao longo de uma sessão e, especialmente, entre diferentes sessões, por limitar bastante a classificação baseada em aprendizagem

prévia.

4.2.1 Derivações Bipolares e Janelas Temporais

É importante reter que, para efeitos de extracção de características, as amostras mais “interessantes” são aquelas que maximizam a classificação, e as mesmas vêm normalmente contidas em determinadas janelas de tempo, após estímulo. Mas como identificar tais amostras?

O procedimento para identificar os segmentos de tempo mais relevantes, do ponto de vista da classificação, passou em primeiro lugar por dividir o problema em sub-problemas:

- Quais os canais mais relevantes?
- Entre os canais mais relevantes, quais os segmentos de tempo (após estímulo) mais favoráveis à classificação?

A “relevância”, neste contexto, é medida pela taxa de classificação obtida numa análise discriminante (LDA) de Fisher. Os dados de entrada para o classificador, em cada passo, são matrizes de 14 linhas, correspondentes a outros tantos valores do logaritmo de DEPs nas frequências 8, 10, 12, ..., 32, 34 Hz, como referido na Secção 4.1. A dimensão das colunas contém amostras concatenadas de vectores de DEPs, como o anterior, associados às amostras que pertencem a intervalos de tempo, após estímulo, pré-estabelecidos.

Em mais detalhe: por cada canal, e para cada par de classes, escolhem-se os vectores contendo as 14 amostras que totalizam a representação espectral de potencial interesse. Por se tratar de um *dataset* com *trials* de longa duração, cada janela considerada contém um segundo de amostras, em 14 intervalos de tempo – $[0, 1[$, $[1, 2[$... $[13, 14[$ segundos – após estímulo.

Para cada uma das matrizes possíveis, antes explicadas, as amostras são aleatoriamente divididas em duas partes iguais: a primeira para treino, a última para teste. Este processo é, depois, repetido 50 vezes e a média das respectivas classificações é registado. Por norma, a primeira janela de tempo após estímulo não é muito relevante, porque os sujeitos têm um tempo de reacção ao tipo de imaginação que é solicitada. Entre as restantes janelas ($[1, 2[$... $[13, 14[$) toma-se a média das médias (*grand average*) nas classificações. Essa medida permitirá definir a importância de cada canal, no problema de classificação.

Como canais de entrada, utiliza-se um conjunto de 28 derivações bipolares obtidas com recurso a alguns dos 32 canais (monopolares) presentes no *dataset* de Martigny. Em três gráficos separados (ver, p.e., a Figura 4.5), mostra-se a classificação média para as melhores 6 derivações bipolares na discriminação de cada par de classes (**E-D**: Esquerda vs. Direita, **E-P**: Esquerda vs. Palavras e **D-P**: Direita vs. Palavras). De notar que os gráficos de “Classificação vs. Janela de Normalização” apresentam a taxa obtida sobre os dados de treino.

Nesta fase, o utilizador da plataforma dispõe de uma apresentação visual da informação que facilita a escolha daqueles canais, entre as derivações bipolares pré-definidas, que favorecem a discriminação de cada par de estados mentais. Vários aspectos podem ser tidos em conta na escolha de tais canais:

- Elevada classificação média;
- Baixa variância;
- Estabilidade da classificação ao longo das janelas de tempo;
- Em casos de imaginação motora, favorecer um arranjo simétrico sobre áreas sensorio-motoras, sempre que essa combinação não prejudique a classificação;

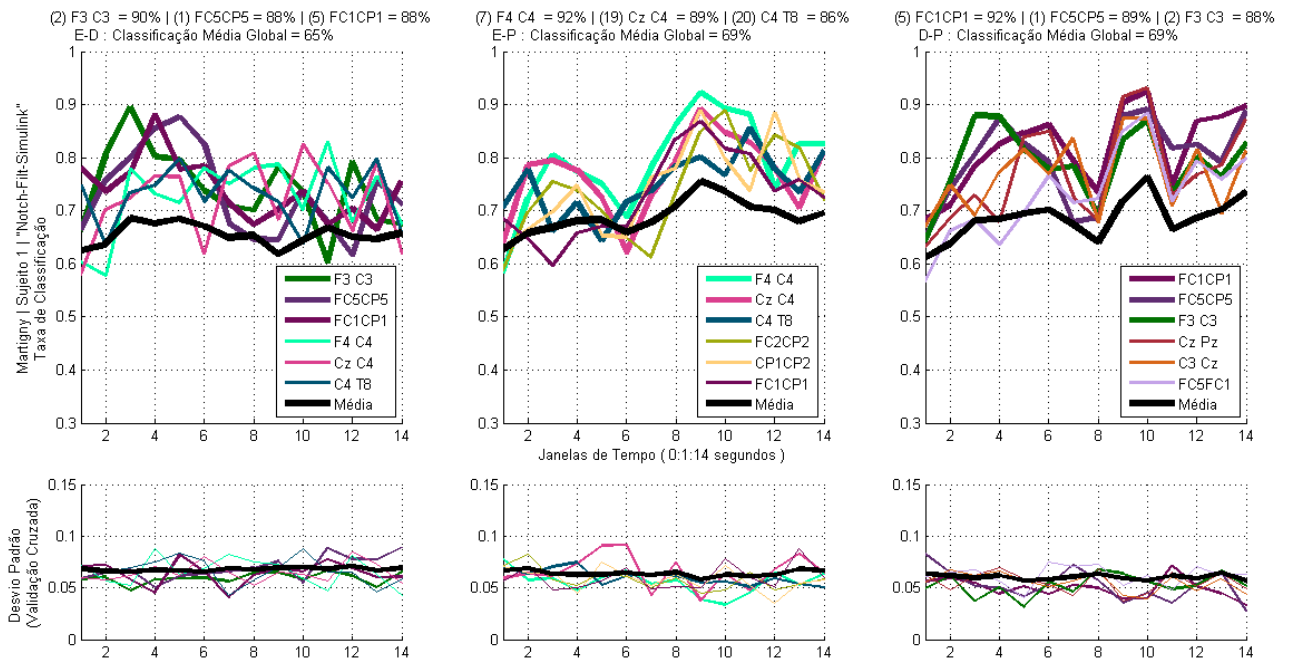


Figura 4.5: Derivações bipolares mais relevantes para o Sujeito 1 de Martigny, na discriminação de cada par de classes.

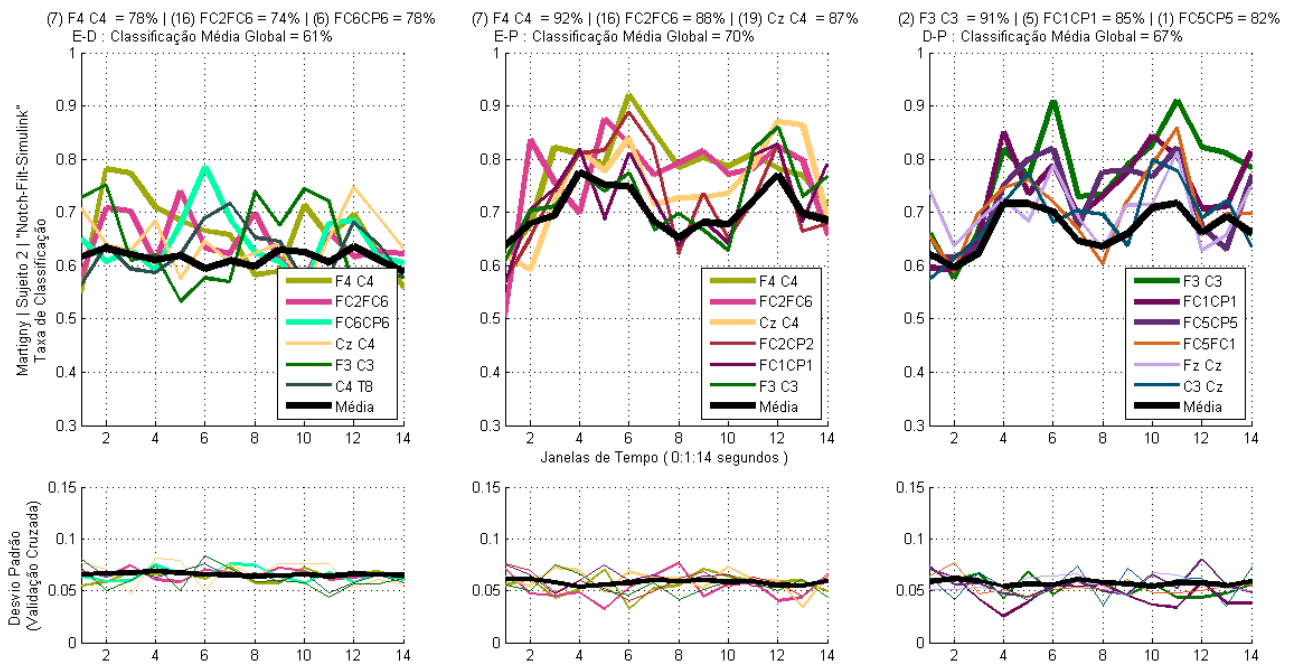


Figura 4.6: Derivações bipolares mais relevantes para o Sujeito 2 de Martigny, na discriminação de cada par de classes.

- O número de canais/derivações deve ser limitado.

Actuando apenas no conjunto de dados de treino, cada cor representa uma derivação bipolar, e mostram-se apenas as seis mais “importantes”, legendadas por ordem decrescente. A traço mais

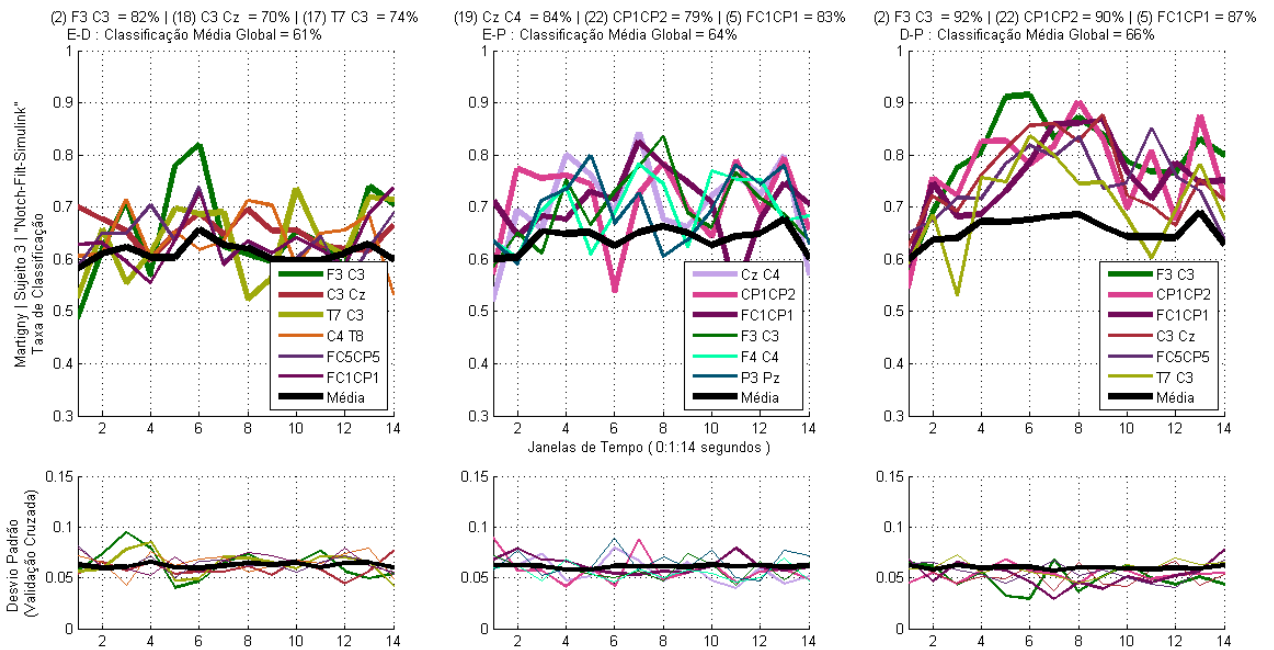


Figura 4.7: Derivações bipolares mais relevantes para o Sujeito 3 de Martigny, na discriminação de cada par de classes.

marcado estão aquelas três que, em média (*grand average*), discriminam melhor cada par de classes e, no título, indicam-se os seus valores de pico. Os gráficos do desvio padrão relativo associado dão uma medida do nível de confiança dos cálculos.

Recordar que, até ao momento, o classificador (LDA de Fisher) validou cada canal, em sucessivas janelas de tempo, usando como entrada as estimativas de DEP na totalidade das frequências consideradas. Como pode verificar-se na generalidade dos casos, encontra-se um grupo restrito de derivações bipolares para as quais a discriminação é largamente superior ao valor médio (que se representa a traço preto).

4.2.2 Frequências Relevantes para Discriminação

Identificados os canais de interesse, a fase seguinte do processo de aprendizagem consiste em determinar quais as frequências que mais contribuem para a correcta classificação. Seleccionam-se, em cada sujeito, as melhores três derivações bipolares. Para cada uma delas, procura-se a janela de tempo após estímulo – com duração de 1 segundo – mais discriminante. O amostras nestas condições são concatenadas em matrizes, em tudo idênticas às do processo de aprendizagem anterior, que servirão de entrada ao classificador DSLVQ.

Como apontado na Secção 3.2.2.1, o classificador DSLVQ tem vários pontos fortes. O principal será, porventura, a habilidade em atribuir um peso a cada característica de entrada. Dessa forma, identifica quais as *features* mais relevantes como ainda a combinação entre elas. Nesta fase, por “características” devem entender-se frequências num dado canal, num total de 14 para o caso de Martigny (linhas de cada matriz). O processo de validação cruzada é em tudo semelhante ao descrito anteriormente: o algoritmo é repetido, agora 75 vezes, tomando como entrada metade das amostras (colunas da matriz) destinadas ao treino, escolhidas aleatoriamente em cada passo de repetição.

Para classificação, usa-se (em cada repetição) a metade das amostras dedicada a teste para calcular

uma variante “pesada” da distância euclideana (tal como definida na Secção 3.16) aos seis vectores de referência devolvidos pelo algoritmo. A cada amostra, associa-se a classe do vector de referência (*codebook vector*) que lhe estiver mais próximo (num espaço de características “*Distinction Sensitive*”), e a taxa de correspondência nos dados de treino é registada. Igualmente importante, regista-se também o vector de “pesos” em cada repetição.

No final do processo, procura-se a melhor classificação obtida nas 75 repetições do algoritmo DSLVQ, mas esta escolha poderá não ser tão trivial como aparenta! Tomem-se dois exemplos na discriminação entre duas classes, onde a correspondência foi de 75% em ambos. Para o primeiro, contudo, a classificação parcial para as duas classes é 50% e 100%, respectivamente, e no segundo 70% e 80%. Naturalmente, o último caso consegue uma detecção mais “justa” que o primeiro, pelo que o critério usado para quantificar os dois aspectos referidos – classificação e distribuição – passou por tomar a média entre a taxa global e a taxa da classe pior detectada. Nestas condições, para o exemplo apresentado, os valores para efeitos meramente comparativos seriam 62.5% e 72.5%, respectivamente.

Identificada a melhor repetição, à luz do critério anterior, e escolhendo também aquelas que se aproximaram, pelo menos, 90% desse valor, tomam-se os vectores dos “pesos” associados e faz-se a média entre eles. Os resultados, para cada sujeito, ilustram-se de seguida.




Figura 4.8: Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes

Nos cabeçalhos de cada Figura (4.8 – 4.16), estão identificadas as três derivações bipolares, bem como os segmentos de tempo em que cada uma atinge o pico na classificação. Mostra-se a quantidade de repetições, do algoritmo DSLVQ, usadas no cálculo da média dos “pesos”, apresentada em cada gráfico. Como se referiu, esse grupo de resultados está ao nível do melhor (90%), e o cálculo da média aumenta a confiança no processo de aprendizagem. Uma outra medida desta confiança diz respeito ao número de repetições em si. Se for reduzido, mostra que o processo de treino – na respectiva repetição – usou um sub-conjunto muito favorável de amostras, quando comparado à maior parte das escolhas feitas aleatoriamente sobre metade dos dados disponíveis para treino. Adicionalmente, mostra-se também em cabeçalho o resultado da classificação para a melhor repetição.




Figura 4.9: Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes




Figura 4.10: Frequências mais discriminantes, para o Sujeito 1 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes




Figura 4.11: Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes




Figura 4.12: Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes




Figura 4.13: Frequências mais discriminantes, para o Sujeito 2 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes




Figura 4.14: Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Esquerda vs. Mão Direita”, na janela de 1s mais favorável a cada par de classes




Figura 4.15: Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Esquerda vs. Palavras”, na janela de 1s mais favorável a cada par de classes




Figura 4.16: Frequências mais discriminantes, para o Sujeito 3 de Martigny, relativa à discriminação “Mão Direita vs. Palavras”, na janela de 1s mais favorável a cada par de classes

4.2.3 Evolução da Classificação

Como já apontado, existem momentos em que a detecção não é bem conseguida. Tal facto poderá dever-se a falhas de concentração dos sujeitos de teste em certas fases, já que dispõe de bastante tempo para realizar cada actividade mental. Embora se compare, numa primeira fase, o nível de distinção entre cada um dos três pares de estados específicos ao *dataset*, o esquema de classificação desenvolvido é um conjunto de três classificadores LDA de Fisher que, por voto de maioria, atribuem a cada amostra a classe prevista (ou ainda “zero”, em situações de indecisão). Tal implementação é bastante susceptível à introdução de falsos positivos, em particular nos instantes de tempo em que os padrões não sejam reconhecíveis, pelo que este método de classificação, por si só, não seria viável em experiências *online*; os gráficos apresentados pretendem ilustrar essa dificuldade. Contudo, quando se pretende que a classificação se processe a um ritmo igual, ou próximo, à taxa de aquisição dos dados, os falsos positivos são inevitáveis e a sua redução é conseguida suavizando os resultados do classificador; a equação 4.2 descreve a técnica usada para esse efeito.

Enquanto processo final de classificação, seleccionam-se as derivações bipolares mais relevantes a cada sujeito e um sub-conjunto limitado de frequências, resultantes da análise de cada gráfico. As escolhas admitidas foram as que constam na Tabela 4.1.

Sujeito	Deriv. Bipolares	Frequências (em Hz)	Nº de Features
1	F3-C3, F4-C4, C3-Cz, Cz-C4 e CP1-CP2	8-14 e 18-28	50
2	F3-C3, F4-C4, FC5-FC1 e FC2-FC6	8-12 e 22-28	44
3	F3-C3, F4-C4, C3-Cz, Cz-C4 e CP1-CP2	10-18 e 24-26	35

Tabela 4.1: Combinações Derivações-Frequências escolhidas com base nos dados de treino de cada sujeito de Martigny

Tendo como entrada uma matriz com a quantidade de *features* destacadas na Tabela 4.1, faz-se a discriminação linear sobre as amostras correspondentes, e disponíveis para treino. No caso de Martigny, dispõem-se das três primeiras sessões de cada sujeito, num conjunto de quatro³. Um classificador LDA é treinado para cada par de classes e, por cada uma dessas operações, resulta um vector de transformação para um espaço 1-dimensional. O critério para discriminação entre pares de classes será o *threshold* escolhido de acordo com o critério formulado na Equação 3.23.

No final, cada classificador (“E-D”, “E-P” e “D-P”) transforma a totalidade dos dados no seu próprio espaço 1D, decidindo sobre os dados de teste (última sessão) com base no *threshold* obtido no treino. A cada amostra é atribuída uma classe sempre que existir consenso em dois classificadores.

Uma vez que a distância ao *threshold* da amostra transformada não foi ainda contabilizado, apenas o seu sinal (ou posição relativa), os *labels* produzidos poderão oscilar bastante. Enquanto último passo passo de classificação, faz-se o *smooth* dos resultados com base em 1 segundo de amostras passadas. A normalização dos resultados produzidos pelo classificador será, contudo, o objecto de estudo seguinte. No procedimento que se apresenta para o efeito, a classe com maior frequência de ocorrência (*f_{OC}*), nas últimas *N* amostras e entre as *N_C* classes consideradas, neste caso 3, será a seleccionada e uma função distância (normalizada) é calculada da seguinte forma:

$$d_n = \frac{(f_{OC} - \frac{N}{N_C})}{\frac{(N_C-1) \cdot N}{N_C}}, \forall f_{OC} > \frac{N}{N_C} \quad (4.1)$$

³ As quatro sessões foram registadas no mesmo dia. Cada uma tem a duração aproximada de 4 minutos e o intervalo entre as mesmas foi de 15 minutos.

$$d_n = 0, \forall \mathbf{f}_{OC} \leq \frac{N}{N_C} \quad (4.2)$$

Esta normalização previne mudanças abruptas no resultado da classificação e permite transições suaves (“zero crossing”) no feedback específico a cada classe. A desvantagem é a introdução de um atraso adicional no *feedback*.

Os resultados para os três sujeitos ilustram-se nas Figuras 4.17 – 4.19. No cabeçalho, consta a classificação obtida nos **dados de teste**, usando janelas de 1 segundo.




Figura 4.17: Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 1 de Martigny

Na Figura 4.20 mostra-se também o resultado de usar como entrada a totalidade das “*features*” disponíveis, ao invés da pré-selecção definida na Tabela 4.1, para o caso do Sujeito 3.




Figura 4.18: Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 2 de Martigny




Figura 4.19: Evolução da Classificação com função da escolha da janela de tempo para normalização, no Sujeito 3 de Martigny




Figura 4.20: Classificação alternativa, ilustrada para o Sujeito 3 de Martigny, usando agora a totalidade das “*features*” disponíveis, num total de 28 derivações bipolares vezes 14 frequências (i.e., 392 “*features*” de entrada)

4.3 Análise dos dados de Berlim

O segundo banco de testes contempla a classificação obtida, para os cinco sujeitos dos dados de Berlim, como função da escolha de janelas de tempo após o estímulo. Dada a especificidade deste *dataset*, onde os estímulos duram 3.5 segundos e, portanto, são bastante mais curtos que os de Martigny, usaram-se 7 janelas de tempo para recolha de amostras, com durações de 0.5 segundos.

Adicionalmente, dado que existem agora dois estados de imaginação motora, optou-se neste caso por um único LDA de Fisher aplicado aos segmentos de tempo que, em média, são mais favoráveis para cada sujeito; cada um deles executou 280 tarefas (*trials*) de imaginação (motora) do pé ou mão direitos.

4.3.1 Estudo com Derivações Bipolares

A metodologia de processamento e aprendizagem sobre as amostras é em tudo semelhante à já descrita no primeiro banco de testes. No entanto, nos dados de Berlim existem 118 canais, pelo que foi possível adoptar derivações bipolares em configurações ligeiramente diferentes, resultando nos 23 casos dispostos na Figura 4.21. De novo, poderá verificar-se que os sujeitos não reagem imediatamente após o estímulo (levam, em média, cerca de um segundo a atingir estados mentais discriminantes).




Figura 4.21: Distribuição de eléctrodos EEG utilizada. O sentido das setas entre eléctrodos mostra as derivações bipolares analisadas ($\oplus \rightarrow \ominus$)

Escolhidas as três derivações bipolares que apresentaram melhores resultados médios no intervalo de 1 a 3.5 segundos, seleccionou-se para cada uma delas o conjunto de amostras (de ambas classes) contidas na janela de tempo, de duração 0.5 segundos, que resulta na classificação máxima. À semelhança do estudo de Martigny mostra-se, nas Figuras 4.24, 4.27, 4.30, 4.33 e 4.36, a relevância de 15 frequências utilizadas – numa gama entre 7 e 36 Hz, com resolução 2 Hz – recorrendo ao algoritmo de extracção de características DSLVO.

4.3.1.1 Sujeito “aa”




Figura 4.22: Derivações bipolares *versus* janelas de tempo mais discriminantes, para o sujeito “aa” de Berlim




Figura 4.23: Frequências mais relevantes, para o sujeito “aa” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso

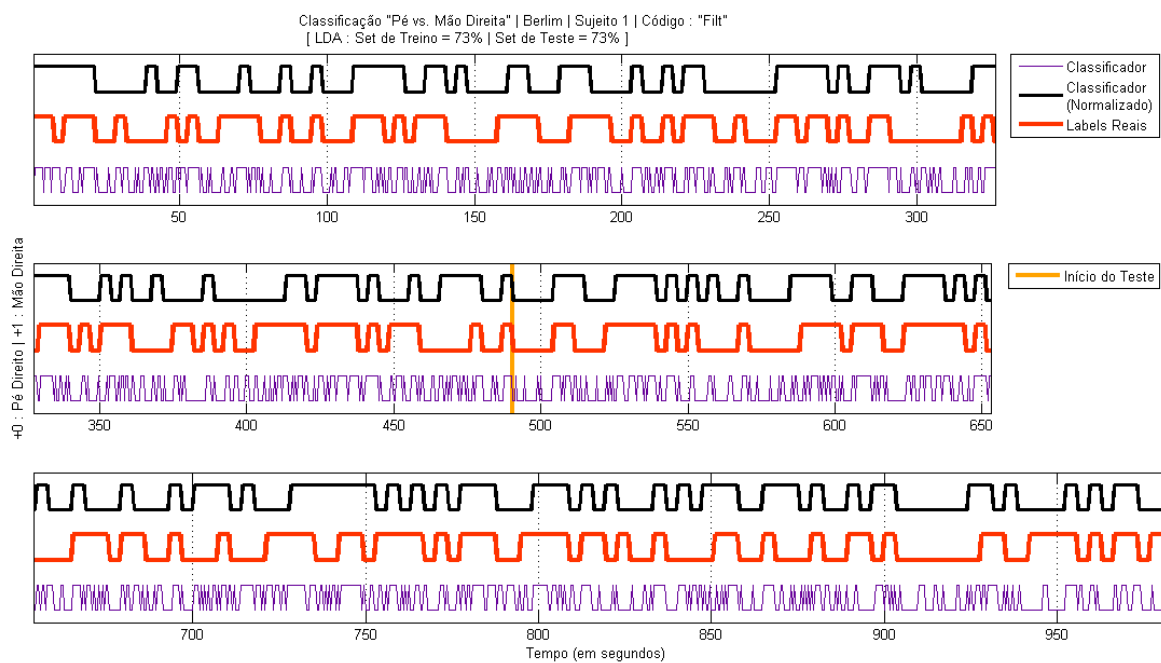


Figura 4.24: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “aa” de Berlim

4.3.1.2 Sujeito “al”




Figura 4.25: Derivações bipolares *versus* janelas de tempo mais discriminantes, para o sujeito “al” de Berlim




Figura 4.26: Frequências mais relevantes, para o sujeito “al” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.27: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “al” de Berlim

4.3.1.3 Sujeito “av”




Figura 4.28: Derivações bipolares *versus* janelas de tempo mais discriminantes, para o sujeito “av” de Berlim




Figura 4.29: Frequências mais relevantes, para o sujeito “av” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.30: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “av” de Berlim

4.3.1.4 Sujeito “ay”




Figura 4.31: Derivações bipolares *versus* janelas de tempo mais discriminantes, para o sujeito “aw” de Berlim




Figura 4.32: Frequências mais relevantes, para o sujeito “aw” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso

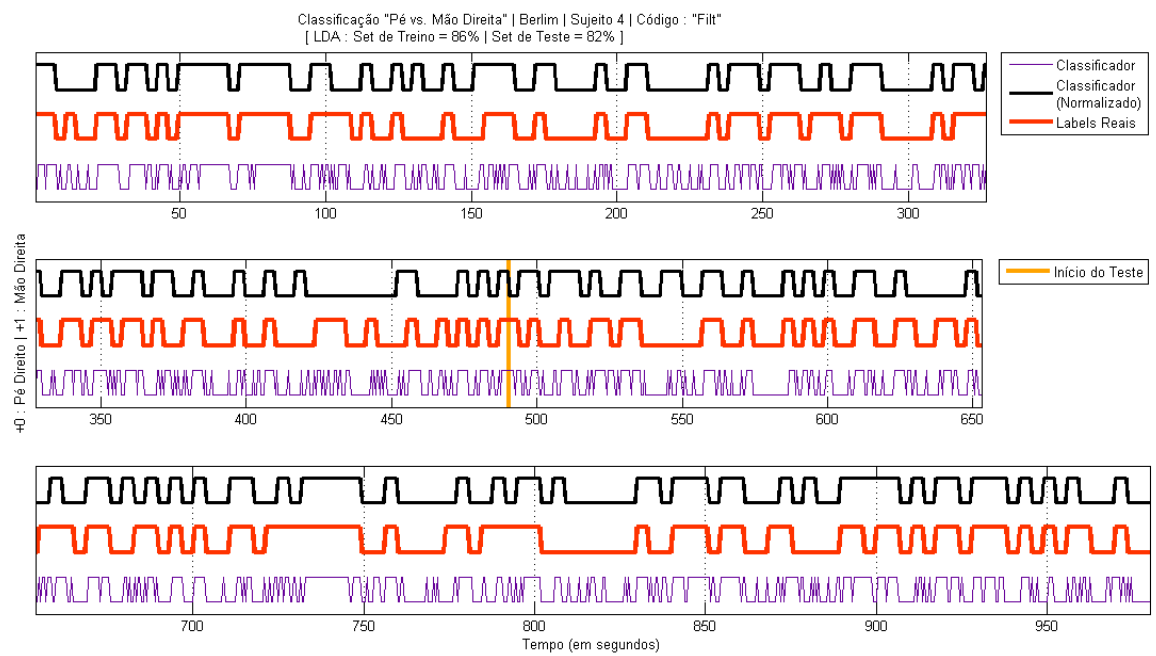


Figura 4.33: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “aw” de Berlim

4.3.1.5 Sujeito “aw”




Figura 4.34: Derivações bipolares *versus* janelas de tempo mais discriminantes, para o sujeito “ay” de Berlim




Figura 4.35: Frequências mais relevantes, para o sujeito “ay” de Berlim, nas três derivações bipolares mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso

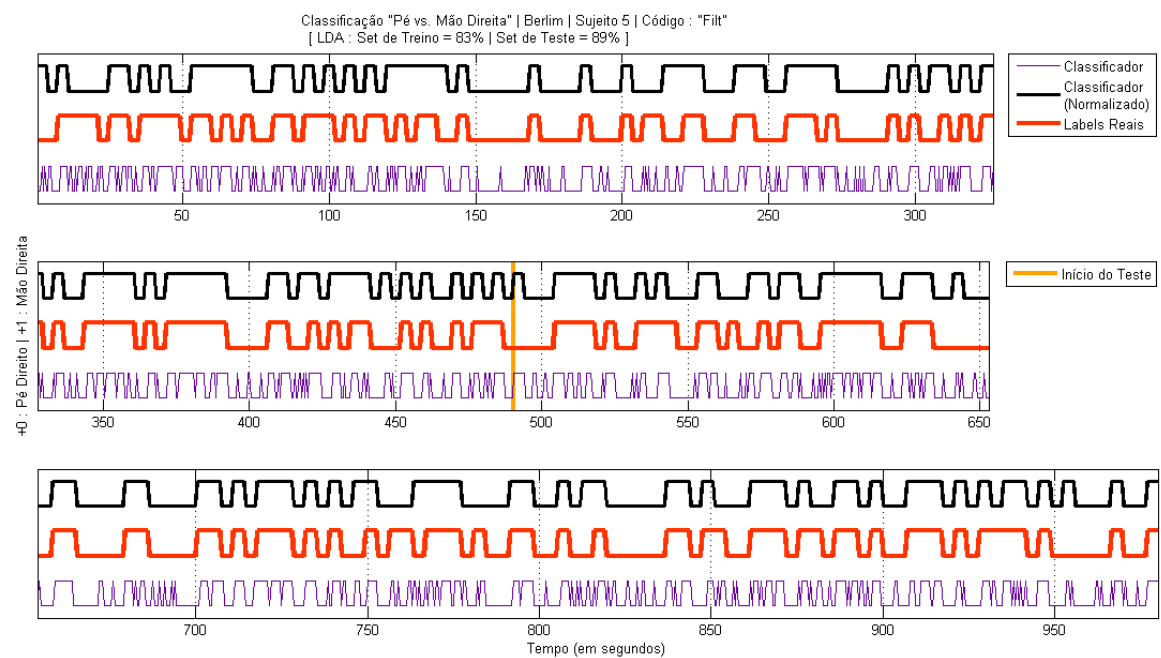


Figura 4.36: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “ay” de Berlim

4.3.2 Estudo com Componentes Independentes (ICA)

Até este ponto, os dados de entrada considerados foram sempre provenientes de derivações bipolares. Na presente secção, partindo de um sub-conjunto de 22 canais monopolares, definiram-se as 23 derivações usadas no dataset de Berlim (rever Figura 4.21).

Uma técnica mais poderosa de separação dos sinais tem vindo a ser utilizada nos mais variados contextos: a análise independente de componentes (Independent Component Analysis, ICA). Trata-se de um método computacional para a separação de sinais multi-variantes⁴ em sub-componentes aditivos, que assume a independência estatística mútua entre os sinais de entrada, considerados não-Gaussianos. É, como tal, um caso especial de *Blind Source Separation* (BSS) que, quando aplicado a sinais EEG, procura transformar os potenciais eléctricos lidos no escalpe em focos independentes de actividade neuronal. Pela sua relativa complexidade, não será dado destaque à formulação matemática que tal transformação envolve.

Utilizando o algoritmo *Infomax*, presente no EEGLab®, procedeu-se à separação da informação contida nos canais monopolares, após uma filtragem na banda $7 - 36\text{Hz}$. Como canais monopolares, foram utilizados, além dos 22 já ilustrados, três outros – $Fp1$, Fpz e $Fp2$ – que, pela sua localização, pretendem evidenciar mais os artefactos oculares. A análise anterior foi repetida, desta vez procurando descobrir a relevância das componentes independentes, e respectivas frequências (Tabela 4.4).

4.3.2.1 Sujeito “aa”




Figura 4.37: Componentes Independentes *versus* janelas de tempo mais discriminantes, para o sujeito “aa” de Berlim

⁴Por sinal multi-variante pretende denotar-se aquele em que é oportuno estudar mais que uma variável estatística.




Figura 4.38: Frequências mais relevantes, para o sujeito “aa” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.39: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “aa” de Berlim

4.3.2.2 Sujeito “al”




Figura 4.40: Componentes Independentes *versus* janelas de tempo mais discriminantes, para o sujeito “al” de Berlim




Figura 4.41: Frequências mais relevantes, para o sujeito “al” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.42: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “al” de Berlim

4.3.2.3 Sujeito “av”




Figura 4.43: Componentes Independentes *versus* janelas de tempo mais discriminantes, para o sujeito “av” de Berlim




Figura 4.44: Frequências mais relevantes, para o sujeito “av” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.45: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “av” de Berlim

4.3.2.4 Sujeito “ay”




Figura 4.46: Componentes Independentes *versus* janelas de tempo mais discriminantes, para o sujeito “aw” de Berlim




Figura 4.47: Frequências mais relevantes, para o sujeito “aw” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso




Figura 4.48: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “aw” de Berlim

4.3.2.5 Sujeito “aw”




Figura 4.49: Componentes Independentes *versus* janelas de tempo mais discriminantes, para o sujeito “ay” de Berlim




Figura 4.50: Frequências mais relevantes, para o sujeito “ay” de Berlim, nas três componentes independentes mais discriminantes, usando a janela de tempo onde a classificação é máxima para cada caso

4.4 Discussão dos resultados

Como pode verificar-se na generalidade dos casos, é possível encontrar um grupo restrito de derivações bipolares para as quais a discriminação é claramente superior ao valor médio. Este valor




Figura 4.51: Evolução da Classificação para os *sets* de treino e teste, no Sujeito “ay” de Berlim

médio calcula-se para cada janela de tempo, usando todas as derivações bipolares (ou componentes independentes), e o facto de variar ligeiramente ao longo do tempo – e estar acima do patamar de uma classificação aleatória⁵ – é também sintomático do contributo de derivações relevantes no cálculo da média.

Do ponto de vista da fenomenologia detectada, no *dataset* de Martigny é evidente a predominância da banda *alpha*, onde se observam variações no níveis de ERD/ERS – nomeadamente dos ritmos *mu* – nos Sujeitos 1 e 3. No Sujeito 2, bandas *alpha* e *beta* mostram uma importância relativa muito próxima no processo de discriminação. No caso de Berlim, em geral, a banda *beta* predomina mais que no caso anterior. Tal gama de frequências tem vindo a ser correlacionada com a imaginação motora dos pés [99], pelo que os resultados vão de encontro ao estado da arte. Também na generalidade dos casos pode observar-se, como seria de esperar, a diminuição do número de falsos positivos com o aumento da janela de tempo para normalização.

Quando usada como entrada a totalidade das “*features*” disponíveis, em vez da selecção considerada mais adequada a cada sujeito – rever Figura 4.20 – verifica-se uma correspondência bastante maior sobre os dados de treino (*i.e.*, aqueles em que houve aprendizagem), mas também uma taxa de erro muito mais acentuada na fase de teste. Para o efeito basta observar o gráfico da evolução da classificação com a janela de normalização, relativo ao treino. Esta evidência está na base de investigação do presente trabalho e pretende mostrar a importância de uma pré-selecção adequada. Assim, a utilização de um número excessivo de “características” pode levar, em algum sentido, a uma “memorização” dos dados por parte do classificador, o que origina uma generalização muito pobre. Omitiram-se os casos dos restantes sujeitos, por terem conduzido a conclusões idênticas.

A Tabela 4.2 condensa os resultados obtidos na discriminação de três estados mentais, para os Sujeitos de teste de Martigny. O desafio apresentado para o *dataset* de Martigny, no âmbito da *BCI Competition III*, é o de obter uma boa classificação dos três estados, sem utilizar mais amostras passadas que aquelas contidas em 1 segundo, tendo em vista paradigmas de operação sem introdução de atrasos significativos na resposta. Adicionalmente, fora do âmbito das regras da competição, mostra-se o resultado (calculado nos **dados de teste**) para as “janelas” de normalização que resultaram

⁵ A classificação que seria obtida, caso a discriminação entre duas classes fosse feita aleatoriamente, é próxima de 50%.

mais discriminantes quando aplicadas aos **dados de treino** recorrendo, naturalmente, a mais amostras para normalização.

Sujeito	Janela de 1 segundo	Melhor Resultado
1	79%	89%
2	73%	81%
3	58%	67%

Tabela 4.2: Classificações obtidas no *set* de competição para cada sujeito de Martigny, no primeiro caso recorrendo a 1 segundo de amostras (passadas), e no segundo caso obtidas à custa de janelas de normalização maiores e, portanto, mais favoráveis à classificação

Durante a competição, houve participantes que, por (alegada) falta de clareza na definição das regras, recorreram a janelas de normalização superiores. As Figuras 4.52 e 4.53 apresentam os três melhores resultados, para ambos casos⁶.

#.	contributor	psd	acc	s1	s2	s3	research lab	co-contributors
1.	Ferran Galan	y	68.65	79.60	70.31	56.02	University of Barcelona	Francesc Oliva, Joan Guardia
2.	Xiang Liao	y	68.50	78.08	71.66	55.73	University of Electronic Science and Technology of China (UESTC)	Yu Yin, Dezhong Yao
3.	Walter	y	65.90	77.85	66.36	53.44		

Figura 4.52: Melhores resultados obtidos na BCI Competition III, para o dataset de Martigny, de acordo com as regras. O campo “psd” indica se os sujeitos utilizaram um conjunto pré-calculado de DEPs, também disponibilizadas na competição; no caso do presente estudo, como se sabe, fez-se toda a cadeia de pré-processamento, pelo que os dados “psd” foram ignorados

#.	contributor	psd	acc	s1	s2	s3	research lab	co-contributors
1.	John Q. Gan	y	80.66	95.98	79.49	67.43	University of Essex, Colchester	Louis C.S. Tsui
2.	David R. Hardoon	y	78.98	90.18	79.03	67.66	University of Southampton	Charanpal Dhanjal, Zakria Hussain
3.	Louis C.S. Tsui	n	76.88	96.60	75.79	58.49	University of Essex, Colchester	John Q. Gan

Figura 4.53: Melhores resultados obtidos na BCI Competition III, no dataset de Martigny, para aqueles participantes que usaram janelas de normalização superiores a 1 segundo, ou outras técnicas de pós-processamento sobre os *labels*

Igualmente relevante foi a detecção de derivações bipolares localizadas predominantemente sobre o córtex pré-motor (PMC) e motor suplementar (SMC), embora também no córtex motor primário (M1), áreas corticais responsáveis pela execução motora. No caso de Berlim, em particular, é observável como os canais mais importantes, na generalidade, são os do hemisfério esquerdo (imaginação motora da mão direita e pé direito).

Em termos de frequência, a análise é também semelhante no caso de Berlim. Agora, são os sujeitos “al”, “aw” e “ay” (segundo, quarto e quinto, respectivamente) a evidenciar maior predominância na banda *alpha* e os sujeitos “aa” e “av” (primeiro e terceiro, respectivamente) a mostrar destaque na banda *beta*. As Tabelas 4.3 e 4.4 condensam as combinações tomadas para *features* em cada sujeito, e respectivas classificações finais. Na primeira, utilizando derivações bipolares e na segunda recorrendo às componentes ICA (resultantes da decomposição de 25 canais monopulares).

Nesta modalidade da *BCI Competition III*, embora próximos, não foram atingidos os melhores resultados, como se indica na Figura img:BCB-Results. A classificação não é, de resto, directamente comparável, já que – no âmbito da competição – a percentagem de dados destinada a teste varia com

⁶Esta informação pode ser consultada em <http://www.bbc.de/competition/iii/results/index.html>

Sujeito	Deriv. Bipolares	Frequências (Hz)	Nº de Features	Taxa
“aa”	FC3-CP3, FC3-C3 e C3-C1	11.7-17.6 e 23.4-27.3	18	73%
“al”	F3-C3, C3-C1 e C3-C1	11.7-17.6 e 25.4-27.3	18	81%
“av”	FC3-C3, FC3-CP3 e CP1-CP2	11.7 e 17.6-29.3	24	69%
“aw”	FC3-CP3, C3-CP3 e C1-CP1	7.8-17.6 e 27.3	18	82%
“ay”	FC3-C3, C3-C1 e FC3-CP3	9.8-17.6 e 23.4-27.3	24	89%

Tabela 4.3: Combinações “Derivações – Frequências” escolhidas com base na primeira metade dos dados de cada sujeito de Berlim, e respectivas classificações, aplicadas à segunda metade dos dados, relegados para teste

Sujeito	Comp. Independentes	Frequências (Hz)	Nº de Features	Taxa
“aa”	11	11.7-15.6 e 27.3-29.3	5	87%
“al”	10, 18 e 12	9.8-17.6 e 23.4-27.3	21	94%
“av”	16 e 10	13.7-23.4 e 31.3	14	70%
“aw”	18, 7 e 11	9.8-15.6	12	94%
“ay”	7	9.8-13.7 e 21.5-25.4	6	86%

Tabela 4.4: Combinações “Componentes Independentes – Frequências” escolhidas com base na primeira metade dos dados de cada sujeito de Berlim, e respectivas classificações, aplicadas à segunda metade dos dados, relegados para teste

cada um dos cinco sujeitos. Por uma questão de simplicidade na análise, o conjunto de dados de Berlim foi – como já explicado – dividido em duas partes iguais: uma para treino, outra para teste.

#	contributor	acc	aa	al	av	aw	ay	research lab	co-contributors
1.	Yijun Wang	94.17%	95.5%	100.0%	80.6%	100.0%	97.6%	Tsinghua University, Beijing	Han Yuan, Dan Zhang, Xiaorong Gao, Zhiguang Zhang, Shangkai Gao
2.	Yuanqing Li	85.12%	89.3%	98.2%	76.5%	92.4%	80.6%	Institute for Infocomm Research, Singapore	Xiaoyuan Zhu, Cuntai Guan
3.	Liu Yang	83.45%	82.1%	94.6%	70.4%	87.5%	88.1%	National University of Defense Technology, Changsha, Hunan	Zhou Zongtan, Zang Guohua, Hu Dewen

Figura 4.54: Melhores resultados obtidos na BCI Competition III, no dataset de Berlim

Por fim, destaca-se a importância da decomposição ICA no tratamento de dados EEG. Em três dos cinco sujeitos testados, a utilização de componentes independentes garantiu melhores resultados, permitindo que, em média, os resultados da discriminação nos cinco sujeitos tenha subido de 79% para 86%.

Capítulo 5

Conclusões

*“ As far as the laws of mathematics refer to reality, they are not certain.
As far as they are certain, they do not refer to reality. ”*

– Albert Einstein

Os dados experimentais podem ser obtidos à custa de uma variedade de tecnologias, com os inerentes pontos fortes e fracos. Por razões relacionadas com o paradigma de utilização e custo associado a cada tecnologia, optou-se pelo estudo de sinais EEG que, à data, são os dominantes na área de Interfaces Cérebro-Computador.

Como se demonstrou, tais sinais têm especificidades que variam com o tempo, a frequência e a localização dos eléctrodos. Um reconhecimento de padrões fiável pode então ser obtido conjugando estas três “dimensões”, mas fazê-lo envolveu vários compromissos. Em primeiro lugar, existe um limite na resolução tempo-frequência que pode ser conseguido e que, em muitos sentidos, lembra o princípio de incerteza postulado por Heisenberg. No domínio espacio-temporal, o desafio está no facto de os potenciais eléctricos lidos no escalpe se apresentarem fortemente atenuados e dispersos, pelo que não correspondem a uma representação muito fiel do foco de excitação em causa, mas antes a uma sobreposição de vários outros, provenientes de zonas próximas. Neste contexto, a análise independente de componentes (ICA) mostrou a sua utilidade na transformação do espaço de características, devolvendo dados correlacionados com os focos de interesse entre a actividade neuronal. A inovação terá sido, porventura, sujeitar tais componentes independentes ao processo de aprendizagem implementado. Pela observação das suas distribuições espaciais de energia fornecidas pelo *EEGLab* (Secção 4.3), que dão uma noção da localização dos focos de actividade neuronal em causa, pode especular-se sobre a validade da técnica de decomposição, mas também do processo de aprendizagem em si.

Para o pré-processamento de dados EEG, a plataforma de *software* desenvolvida é “sensível” ao ajuste de variados aspectos, como sejam o método de filtragem, o tamanho da janela de tempo para estimação da DEP (traduzido em número de amostras), a percentagem de sobreposição das referidas janelas ou ainda o método, tamanho e ordem de estimação das janelas FFT. Os testes foram levados a cabo usando *datasets* que, tendo sido recolhidos em condições análogas às pretendidas para operação assíncrona de uma BCI, se revelaram adequados. Não só se determinou a relevância entre a gama de características na entrada, como ainda as combinações mais favoráveis entre elas, ficando reforçada a importância do método de selecção de características.

As características de interesse ao presente estudo foram a localização óptima dos eléctrodos no

escalpe e as frequências (ou gamas de frequências) onde, para cada sujeito, os padrões a reconhecer são mais facilmente separáveis¹. Fenómenos ERD em ritmos nas bandas *alpha* ou *beta* inferior são característicos de áreas corticais prontas a processar informação ou preparar um movimento, enquanto fenómenos ERS nas mesmas bandas podem ser vistos como correlações electrofisiológicas de áreas corticais em repouso. A sua detecção baseou-se no cálculo da densidade espectral de potência que, enquanto quantidade numérica, se revelou adequada no processo de aprendizagem.

Foi interessante, então, compreender como a importância das bandas *alpha* e *beta* está fortemente dependente do sujeito. Igualmente relevante foi a detecção de derivações bipolares localizadas predominantemente sobre o córtex pré-motor (PMC) e motor suplementar (SMC), embora também no córtex motor primário (M1), áreas corticais responsáveis pela execução motora.

O método de *learning* descrito, pela sua simplicidade e transparência, pode ser aplicado aos mais variados paradigmas de operação com BCIs. Para o efeito, contempla-se uma fase de treino onde é usado um *setup* alargado de canais monopolares, e considerada uma banda de frequência bastante generalista. Entre estas características, são seleccionadas aquelas que, mediante uma série de pré-requisitos, maximizam a classificação. Nestas condições, *i.e.*, usando o sub-conjunto das *features* (consideradas) mais adequadas a cada sujeito, comprovou-se um acentuado acréscimo de desempenho na tarefa final de classificação. Tais características servirão, em última análise, não apenas para efeitos de classificação, mas com o propósito maior de, uma vez atingida a fase de testes *online*, se poder recorrer a um número limitado de canais monopolares e definir os filtros de interesse. Sendo necessários menos canais, há uma poupança em recursos computacionais e no tempo de colocação dos eléctrodos que, quando devidamente seleccionados, melhoram a *performance* do classificador.

Para suporte a testes *online*, além dos ambientes gráficos para treino e experiências, desenvolveu-se uma versão mais robusta do classificador LDA de Fisher utilizado na discriminação entre classes de imaginação motora. Tal classificador pretende detectar se existe intenção de controlo por parte do sujeito de teste, e aparece em primeiro lugar na árvore de decisões. A sua diferença consiste na introdução de um nível de *threshold* que possa garantir alguma imunidade a falsos positivos, mas possivelmente também um período de treino dos sujeitos de teste. Por fim, enquanto parâmetros de ajuste da reactividade do classificador, é possível em fases de calibração configurar duas durações mínimas, uma para o estado de controlo e outra para o estado de ausência de intenção.

Perspectivas de Continuidade

Uma vez cumpridas as etapas do plano de trabalho, podemos enumerar um conjunto de aspectos a merecer atenção numa perspectiva de trabalho futuro:

- Integrar técnicas adicionais de aprendizagem e classificação na plataforma desenvolvida, nomeadamente algumas das descritas na Secção 3.2.1. Em particular, o algoritmo *Common Sub-Space Decomposition* (CSSD) – vencedor na BCI Competition III para os dados de Berlim [8] – tem sido usado[87], inclusivamente com propósitos idênticos aos do presente projecto[88].
- Explorar métodos para detectar e, sempre que possível, corrigir artefactos.
- Desenvolver um sistema integrado de treino que permita investigar as vantagens do treino da actividade cerebral (*i.e.*, aquisição de um maior controlo sobre as actividades do utilizador) quando inserido num ambiente imersivo de realidade virtual;

¹No processo de aprendizagem, “características” subentendem canais ou frequências; no processo final de classificação, contudo, traduzem uma combinação favorável de ambos.

- Implementar um sistema de navegação em ambientes virtuais, combinando os sistemas BCI-RV para realizar "navegação por pensamentos" com realimentação visual de forma a responder à questão: como navegar em ambientes virtuais pela simples imaginação do próprio movimento?

Bibliografia

- [1] Pfurtscheller, G., *et al.* 15 years of bci research at graz university of technology: current projects. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 14(2):205–210, 2006.
- [2] Weiskopf, N., *et al.* Principles of a brain-computer interface (bci) based on real-time functional magnetic resonance imaging (fmri). *Biomedical Engineering, IEEE Transactions on*, 51(6):966–970, 2004.
- [3] Millán, J. del R., *et al.* Noninvasive brain-actuated control of a mobile robot by human eeg. *Biomedical Engineering, IEEE Transactions on*, 51(6):1026–1033, 2004.
- [4] Millán, J. del R., Renkens, F., Mouriño, J. and Gerstner, W. Noninvasive brain-actuated control of a mobile robot. *International Joint Conference on Artificial Intelligence*, 2003.
- [5] Wolpaw, J.R., *et al.* The wadsworth center brain-computer interface (bci) research and development program. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 11(2):1–4, 2003.
- [6] Pfurtscheller, G. Brain-computer interfaces: State of the art and future prospects. *Proceedings of the 12th European Signal Processing Conference, EUROSIPCO'04*, pages 509–510, 2004.
- [7] Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G. and Vaughan, T.M. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6):767–791, 2002.
- [8] Wang, Y. *et al.* Bci competition 2003–data set iv: an algorithm based on cssd and fda for classifying single-trial eeg. *IEEE Trans Biomed Eng.*, 51(6):1081–1086, 2004.
- [9] Müller, K.R., Anderson, C.W. and Birch, G.E. Linear and nonlinear methods for brain-computer interfaces. *IEEE Trans Neural Syst Rehabil Eng.*, 11(2):165–169, Jun 2003.
- [10] Roberts, S. J. and Penny, W. D. Real-time brain-computer interfacing: a preliminary study using bayesian learning. *Medical and Biological Engineering and Computing*, 38(1):56–61, 2000.
- [11] Jung, T.-P. *et al.* Removing electroencephalographic artifacts by blind source separation. *Psychophysiol.*, 37:168–178, 2000.
- [12] Platt, J. C., Cristianini, N. N. and Shawe-Taylor, J. *Advances in Neural Information Processing Systems*. Number 547–553. Solla, S. A., Leen, T. K. and Müller, K. R., 2000.
- [13] M. Prgenzer and G. Pfurtscheller. Frequency component selection for an eeg-based brain to computer interface. *ieee transactions on rehabilitation engineering*, 7(4):413–419, 1999.
- [14] Yang, J. and Honavar, V. Feature subset selection using a genetic algorithm. *Feature Extraction, Construction and Subset Selection: A Data Mining Perspective*, H. Liu and H. Motoda, Eds. Boston, MA: Kluwer Academic, pages 117–136, 1998.

- [15] Whitley, D. *et al.* Messy genetic algorithms for subset feature selection. *Proc. Int. Conf. on Genetic Algorithms*, T. Baeck, Ed., Boston, MA, pages 568–575, 1997.
- [16] Pregenzer, M., Pfurtscheller, G. and Flotzinger, D. Automated feature selection with a distinction sensitive learning vector quantizer. *Neurocomputing*, 11:19–29, 1996.
- [17] Boser, B. E., Guyon, I. M. , and Vapnik, V. A training algorithm for optimal margin classifiers. *Proc. 5th Annu. Workshop on Computational Learning Theory*, Pittsburgh, PA., pages 144–152, 1992.
- [18] Hjorth, B. Principles for transformation of scalp eeg from potential field into source distribution. *Journal of Clinical Neurophysiology*, 8(4):391–396, 1991.
- [19] Kohonen, T. The self-organizing map. *Proc. IEEE*, (78):1464–1480, 1990.
- [20] Bento, V. A., Cunha, J. P., Silva, F. M. Ieeta brain computer interface: Towards a rapid prototyping and multi-application system. In *BIOSIGNALS 2009 - International Conference on Bio-inspired Systems and Signal Processing*, 2009.
- [21] Bento, V. A., Cunha, J. P., Silva, F. M. Towards a human-robot interface based on the electrical activity of the brain. In *Humanoid Robots, 2008. Humanoids 2008. 8th IEEE-RAS International Conference on*, pages 85–90, 2008.
- [22] Gomes, L. C. Brainware: Interação com ambientes multimédia através da actividade cerebral. in *DETI, University of Aveiro (Portugal)*, 2007.
- [23] Leeb, R. *et al.* Exploring virtual environments with an eeg-based bci through motor imagery. *Biomedizinische Technik*, 52:86–91, 2005.
- [24] Leeb, R. *et al.* Using a bci as a navigation tool in virtual environments. *Proc. 2nd International Brain-Computer Interface Workshop and Training Course*, pages 49–50, 2004.
- [25] Vidal, J. J. Toward direct brain-computer communication. *Annual Review of Biophysics and Bioengineering*, 2(1):157–180, 1973.
- [26] Caton, Richard M. D. The electric currents of the brain. *British Medical Journal*, 2:610, 1875.
- [27] Eccles, J. C. The physiology of nerve cells. *Baltimore: Johns Hopkins University Press*, 1957.
- [28] Jack, J.J.B., Noble, D., and Tsien, R.W. *Electric current flow in excitable cells*. Oxford : Clarendon Press, 1975.
- [29] Fechner, Gustav Theodor. *Elemente der Psychophysik*. Thoemmes Continuum, 1860.
- [30] Nudo, R. J. Adaptive plasticity in motor cortex: Implications for rehabilitation after brain injury. *Journal of Rehabilitation Medicine*, (41):7–10, 2003.
- [31] Duffau, H. Brain plasticity and tumors. *Adv Tech Stand Neurosurg*, (33):3–33, 2008.
- [32] Sherwood, C. C., *et al.* Evolution of increased glia-neuron ratios in the human frontal cortex. *Proceedings of the National Academy of Sciences*, 103(37):13606–13611, 2006.
- [33] Alberts, B., *et al.* The nervous system. *Molecular Biology of The Cell*, (19):1059–1136, 1989. Garland Publishing.
- [34] Gehring, W. J. New perspectives on eye development and the evolution of eyes and photoreceptors: The evolution of eyes and brain. *Journal of Heredity*, 96(3):171–184, 2005.

- [35] Nickel, M., Vitello, M., Brümmer, F. Dynamics and cellular movements in the locomotion of the sponge *tethya wilhelma*. *Integrative and Comparative Biology*, 42:1285, 2002.
- [36] Grillner, S., Wallén, P. Cellular bases of a vertebrate locomotor system-steering, intersegmental and segmental co-ordination and sensory control. *Bain research. Brain research reviews*, 40(1–3):92–46, October 2002.
- [37] Lotze, M. *et al.* Activation of cortical and cerebellar motor areas during executed and imagined hand movements: an fmri study. *Journal of Cognitive Neuroscience*, 11(5):491–501, 1999.
- [38] Kasess, C.H., *et al.* The suppressive influence of sma on m1 in motor imagery revealed by fmri and dynamic causal modeling. *Neuroimage*, 40(2):828–837, 2008.
- [39] Hoshi, E. and Tanji, J. Distinctions between dorsal and ventral premotor areas: anatomical connectivity and functional properties. *Current Opinion in Neurobiology*, 17(2):234–242, 2007.
- [40] Hoshi, E. and Tanji, J. Differential involvement of neurons in the dorsal and ventral premotor cortex during processing of visual signals for action planning. *Journal of Neurophysiology*, 95(6):3596–3616, 2006.
- [41] Chung, G. H., *et al.* Functional heterogeneity of the supplementary motor area. *American Journal of Neuroradiology*, 26(7):1819–1823, 2005.
- [42] Lee, Daeyeol. To touch or not to touch: posterior parietal cortex and voluntary behavior. *Neuron*, 56(3):419–421, 2007.
- [43] Rizzolatti, G., Fadiga, L., Gallese, V. and Fogassi, L. Premotor cortex and the recognition of motor actions. *Cognitive Brain Research*, 3(2):131–141, 1996.
- [44] Wang, M. H., Zhu, Y. H., Li, J. C. and Weng, X.C. Functional magnetic resonance imaging of whole brain related to motor preparation and execution. *Zhonghua Yi Xue Za Zhi*, 87(14):971–974, 2007.
- [45] Jeannerod, Marc. The representing brain: Neural correlates of motor intention and imagery. *Behavioral and Brain Sciences*, 17(2):187–245, 1994.
- [46] Roth, M., *et al.* Possible involvement of primary motor cortex in mentally simulated movement. *Neuroreport*, 7(7):1280–1284, 1996.
- [47] Porro, C.A., *et al.* Primary motor and sensory cortex activation during motor performance and motor imagery: a functional magnetic resonance imaging study. *The Journal of Neuroscience*, 16(23):7688–7698, 1996.
- [48] Pineda, J. A. The functional significance of mu rhythms: translating “seeing” and “hearing” into “doing”. *Brain Research Reviews*, 50(1):57–68, 2005.
- [49] Buccino, G., Binkofski, F. and Riggio, L. The mirror neuron system and action recognition. *Brain Lang*, 89(2):370–376, 2004.
- [50] Lametti, D. R. and Mattar, A. A. Mirror neurons and the lateralization of human language. *The Journal of Neuroscience*, 26(25):6666–6667, 2006.
- [51] Hemmen, J. L., Sejnowski, T. J. *23 Problems in Systems Neuroscience*. Oxford University Press, November 2005.

- [52] Gingerich, M.D. Multi-dimensional microelectrode arrays with on-chip cmos circuitry for neural stimulation and recovering. *Center for Wireless Integrated MicroSystems, Department of Electrical Engineering and Computer Science, University of Michigan*, 2002.
- [53] Akin, Tayfun. An integrated telemetric multichannel sieve electrode for nerve regeneration applications. *Dissertation (Ph.D.)—University of Michigan*, 1994.
- [54] Hans Berger. Uber das elektrenkephalogamm des menschen. *Arch. Psychiat. Nervenkr*, 87:527–570, 1929.
- [55] Cohen, D. Magnetoencephalography: Detection of the brain’s electrical activity with a superconducting magnetometer. *Science*, (175):664–666, 1972.
- [56] Anger H. O. Gamma-ray and positron scintillation camera. *Nucleonics*, (21):10–56, 1963.
- [57] Potts, G. F. *et al.* Visual hemifield mapping using transactionscranial magnetic stimulation coregistered with cortical surfaces derived from magnetic resonance images. *Journal of Clinical Neurophysiology*, 15(4):344–350, 1994.
- [58] Wassermann, E. M. *et al.* Locating the motor cortex on the mri with transcranial magnetic stimulation and pet. *Neuroimage*, 3:1–9, 1996.
- [59] Fried, I., Nenovn V. I., Ojemann, S. G., Woods, R. P. Functional mr and pet imaging of rolandic and visual cortices for neurosurgical planning. *Journal of Neurosurgery*, 83:854–861, 1995.
- [60] Cahn, B. R. and Polich, J. Meditation states and traits: Eeg, erp, and neuroimaging studies. *Psychological Bulletin*, 132(2):180–211, 2006.
- [61] Muthukumaraswamy, S. D., Johnson, B.W. and McNair, N.A. Mu rhythm modulation during observation of an object-directed grasp. *Brain research. Cognitive brain research*, 19(2):195–201, 2004.
- [62] Kozelka, J. W. and Pedley, T.A. Beta and mu rhythms. *Journal of Clinical Neurophysiology*, 7(2):191–207, 1990.
- [63] Arroyo, S., *et al.* Functional significance of the mu rhythm of human cortex: an electrophysiologic study with subdural electrodes. *Electroencephalogr Clin Neurophysiol*, 87(3):76–87, 1993.
- [64] Pineda, J. A., Allison, B.Z. and Vankov, A. The effects of self-movement, observation, and imagination on mu rhythms and readiness potentials (rp’s): toward a brain-computer interface (bci). *IEEE Transactions on Rehabilitation Engineering*, 8(2):219–222, 2000.
- [65] Cobb, W. A., Guilloff, R. J. and Cast. J. Breach rhythm: the eeg related to skull defects. *Journal of Clinical Neurophysiology*, 47(3):251–271, 1979.
- [66] Niedermeyer, E. The “third rhythm”: further observations. *Clinical EEG (electroencephalography)*, 22(3):83–96, 1991.
- [67] Pfurtscheller, G. and Lopes da Silva, F. H. Event-related eeg/meg synchronization and desynchronization: basic principles. *Journal of Clinical Neurophysiology*, 110:1842–1857, 1999.
- [68] Pfurtscheller, G. and Cooper, R. Frequency dependence of the transmission of the eeg from cortex to scalp. *Electroencephalogr Clin Neurophysiol*, 38(1):93–96, 1975.
- [69] Graimann, B., *et al.* Detection of erp and erd/ers patterns in single ecog channels. *First International IEEE EMBS Conference on*, 2003.

- [70] Wolpaw, J.R., *et al.* Brain-computer interface research at the wadsworth center. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 8(2):222–226, 2000.
- [71] Vaughan, T. M., *et al.* The wadsworth bci research and development program: at home with bci. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 14(2):229–233, 2006.
- [72] Millán, J. del R., *et al.* Brain-actuated interaction. *Elsevier Science Publishers Ltd*, 159(1–2):241–259, 2004.
- [73] Stavrinou, M. L., *et al.* Evaluation of cortical connectivity during real and imagined rhythmic finger tapping. *Brain Topography*, 19(3):137–145, 2007.
- [74] Strehl, U. *et al.* Self-regulation of slow cortical potentials: A new treatment for children with attention-deficit/hyperactivity disorder. *Official Journal of the American Academy of Pediatrics*, 118(5):1530–1540, 2006.
- [75] Heinrich, H. *et al.* Training of slow cortical potentials in attention-deficit/hyperactivity disorder: evidence for positive behavioral and neurophysiological effects. *Biol. Psychiatry.*, 55(7):772–775, 2004.
- [76] Biyu J. He and Raichle, Marcus E. The fmri signal, slow cortical potential and consciousness. *Trends in Cognitive Sciences*, 13(7):302–309, 2009.
- [77] Bugnariu, N. and Fung, J. Aging and selective sensorimotor strategies in the regulation of upright balance. *Journal of NeuroEngineering and Rehabilitation*, 4(19), 2007.
- [78] Neumann, N. and Kübler, A. Training locked-in patients: A challenge for the use of brain–computer interfaces. *IEEE transactions on neural systems and rehabilitation engineering*, 11(2), 2003.
- [79] Obermaier, B., Müller, G. R. and Pfurtscheller, G. “Virtual Keyboard” Controlled by Spontaneous EEG Activity. *IEEE transactions on neural systems and rehabilitation engineering*, 11(4), 2003.
- [80] James, W. The principles of psychology. vol. 1. *New York: Henry Holt*, 1890.
- [81] Helmholtz, H. Handbuch der physiologischen optik. *Hamburg: Voss*, 1867.
- [82] Posner, M.I. Orienting of attention. *Quarterly Journal of Experimental Psychology*, 32:3–25, 1980.
- [83] Junker, G. *Pro OGRE 3D Programming (Foreword by Steve Streeting, Founder/Lead Developer of OGRE 3D)*. 2006.
- [84] Hussen, F., Horst, P. and Baggerman, J. W. Augmented & virtual reality: Development of applications for a usability study. *Delft University of Technology (Holland) and IEETA (Portugal)*, 2006.
- [85] 3rd Kuala Lumpur International Conference on Biomedical Engineering 2006. *Comparison of different Montages on to EEG classification*, volume 15 of *IFMBE Proceedings*. Springer Berlin Heidelberg, 2007.
- [86] Lemos, M. S. and Fisch, B. J. The weighted average reference montage. *Electroencephalography and Clinical Neurophysiology*, 79(5):361–370, 1991.

- [87] Yan, T., Jingtian, T. and Andong, G. Multi-class eeg classification for brain computer interface based on csp. *BioMedical Engineering and Informatics, International Conference on*, 2:469–472, 2008.
- [88] Farquhar, J. *et al.* Regularised csp for sensor selection in bci. *3rd International Brain-Computer Interface Workshop and Training Course 2006*, pages 21–24, 2006.
- [89] Hastie, T., Tibshirani, R. and Friedman, J. The elements of statistical learning: Data mining, inference, and prediction. *Berlin, Germany: Springer-Verlag*, 2001.
- [90] Whitley, D. A genetic algorithm tutorial. *Statist. Comput.*, 4:65–85, 1994.
- [91] Cover, T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE Trans. Electron. Comput.*, EC-14:326–334, 1965.
- [92] Mercer, J. Functions of positive and negative type, and their connection with the theory of integral equations. *Trans. London Philosoph. Soc.*, A 209:415–446, 1909.
- [93] Garrett, D. *et al.* Comparison of linear, nonlinear, and feature selection methods for eeg signal classification. *IEEE Trans Neural Syst Rehabil Eng.*, 11(2):141–144, Jun 2003.
- [94] Pregoner, M. and Pfurtscheller, G. Distinction sensitive learning vector quantization (dslvq) application as a classifier based feature selection method for a brain computer interface. *Fourth International Conference on Artificial Neural Networks*, pages 433–436, 1995.
- [95] Kohonen, T., Barna, G. and Chrisley, R. Statistical pattern recognition with neural networks: Benchmarking studies. *fioc. IEEE Int. Conf. on Neural Networks*, (1):61–68, 1988.
- [96] Fisher, R. The use of multiple measurements in taxonomic problems in: , 7, p. *Annals of Eugenics*, 7:179–188, 1936.
- [97] Scherer, R., Lee, F., Schlogl, A., Leeb, R., Bischof, H. and Pfurtscheller, G. Toward self-paced brain-computer communication: navigation through virtual worlds. *IEEE Trans Biomed Eng.*, 55(2):675–686, 2008.
- [98] Nitschke, J. B. and Miller, G. A. Digital filtering in eeg/erp analysis: Some technical and empirical comparisons. *Behavior Research Methods, Instruments and Computers*, 30(1):59–67, 1998.
- [99] Pfurtscheller, G., Neuper, C., Andrew, C. and Edlinger, G. Foot and hand area mu rhythms. *International Journal of Psychophysiology*, 26(1):121–135, 1997.